

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

IVANA DUBRAVAC

MOBILNA POSLOVNA INTELIGENCIJA

Diplomski rad

Pula, 2014.

Sveučilište Jurja Dobrile u Puli
Fakultet ekonomije i turizma
„Dr. Mijo Mirković“

IVANA DUBRAVAC

MOBILNA POSLOVNA INTELIGENCIJA

Diplomski rad

Broj indeksa: 294-ED

Studijski smjer: Poslovna informatika

Predmet: Informacijski sustavi u potpori upravljanju i odlučivanju

Mentor: prof. dr. sc. Vanja Bevanda

Pula, listopad 2014.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisana Ivana Dubravac, izjavljujem da je Diplomski rad isključivo rezultat mojeg vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija.

Ivana Dubravac

SADRŽAJ

UVOD	1
1. POSLOVNA INTELIGENCIJA	3
1.1. Infrastruktura sustava poslovne inteligencije	5
1.2. Razvoj sustava poslovne inteligencije	10
1.3. Dobavljači sustava poslovne inteligencije	17
1.4. Budućnost poslovne inteligencije	19
1.5. Primjena poslovne inteligencije u Hrvatskoj i svijetu	20
2. SUSTAVI MOBILNE POSLOVNE INTELIGENCIJE.....	22
2.1. Povijesni razvoj mobilne poslovne inteligencije	23
2.2. Prednosti i nedostaci MPI	25
2.2.1. <i>Prednosti MPI</i>	25
2.2.2. <i>Nedostaci MPI</i>	26
2.3. Specifičnosti mobilne poslovne inteligencije.....	27
2.4. Razvoj sustava mobilne poslovne inteligencije.....	30
2.4.1. <i>Nativne mobilne aplikacije (engl. Native mobile applications)</i>	33
2.4.2. <i>Web bazirana rješenja (engl. Browser based applications)</i>	34
2.4.3. <i>Nativno hibridno rješenje</i>	34
2.4.4. <i>Hibridno web bazirano rješenje</i>	35
2.4.5. <i>Računalstvo u oblaku i mobilna poslovna inteligencija</i>	36
2.5. Sigurnost podataka na mobilnoj poslovnoj inteligenciji.....	39
2.5.1. <i>Sigurnost na razini uređaja</i>	40
2.5.2. <i>Sigurnost prijenosa podataka</i>	40
2.5.3. <i>Autorizacija, autentifikacija i mrežna sigurnost</i>	40
2.6. Primjena mobilne poslovne inteligencije	40

3. ISTRAŽIVANJE POSLOVNE I MOBILNE POSLOVNE INTELIGENCIJE U HRVATSKOJ.....	42
3.1. Usporedba rezultata istraživanja korištenja poslovne inteligencije.....	65
3.2. Usporedba istraživanja mobilne poslovne inteligencije u hrvatskoj i svijetu	70
4. ZAKLJUČAK	79
LITERATURA:.....	82
POPIS SLIKA	85
POPIS TABLICA.....	87
SAŽETAK	88
SUMMARY	89

Informacija je ishodište učenja. Ali ako nije organizirana, obrađena i stavljena na raspolaganje odgovornim osobama u formatu prikladnom za odlučivanje, ona je teret, a ne korist.

William Pollard

UVOD

U današnje vrijeme tvrtkama je sve veći problem opstati na tržištu ili postići konkurentnost. Opseg informacija s kojima se tvrtke susreću je golem te ih treba obraditi na način da postanu korisne u donošenju dobrih poslovnih odluka što je i temelj poslovanja.

Glavna hipoteza diplomskog rada je da u malim i srednjim poduzećima u Republici Hrvatskoj nije prepoznata važnost korištenja poslovne i mobilne poslovne inteligencije za donošenje poslovnih odluka i ostvarivanje poslovnih rezultata, a slijedom toga ne postoje niti dobre strategije za upravljanje podacima koje podupiru poslovne ciljeve poduzeća.

Ostale, pomoćne hipoteze koje su obrađene ovim radom su:

Sustavi mobilne poslovne inteligencije su bitni u današnjem poslovanju, jer pružaju točne i pravovremene informacije, a tvrtkama koje ih koriste, donosi višestruke koristi.

Najveća prepreka uvođenju takvih sustava je nedovoljna educiranost korisnika.

Cilj ovog diplomskog rada je opisati sustave poslovne i mobilne poslovne inteligencije te istražiti njihovu primjenu u malim i srednjim poduzećima u Republici Hrvatskoj, a dobiveno istraživanje usporediti sa sličnim istraživanjima u svijetu.

U današnje vrijeme, odluke je bitno donositi pravovremeno i moraju se temeljiti na točnim, kvalitetnim i pravodobnim informacijama i upravno tome služi poslovna inteligencija.

Predmet istraživanja ovog rada su sustavi poslovne i mobilne poslovne inteligencije, njihov pojam, struktura i upotreba u hrvatskim poduzećima.

Ovaj diplomski rad se sastoji četiri cjeline.

U uvodnom dijelu bit će opisana svrha diplomskog rada, njegova struktura i ciljevi. Bit će iznijeta hipoteza rada, ciljevi i metode istraživanja.

U prvom dijelu rada, pod naslovom „Poslovna inteligencija“ opisani su sustavi poslovne inteligencije, njihov povijesni razvoj i infrastruktura. Navedeni su najbitniji dobavljači s tog područja te je ukratko opisana budućnost sustava poslovne inteligencije.

U središnjem dijelu rada koji nosi naslov „Sustavi mobilne poslovne inteligencije“ su opisani sustavi mobilne poslovne inteligencije. Opisana je njihova infrastruktura te povijesni razvoj. Dan je pregled prednosti i nedostataka takvih sustava, pravci razvoja i vrste sigurnosti podataka na mobilnim uređajima.

Pod četvrtim naslovom diplomskog rada, izneseni su rezultati istraživanja provedenog u malim i srednjim poduzećima u Republici Hrvatskoj te usporedba dobivenih rezultata sa rezultatima svjetskih istraživanja u vezi poslovne i mobilne poslovne inteligencije.

U zadnjem dijelu iznesena su zaključna razmišljanja proizašla iz pisanja ovog rada i provedbe istraživanja.

1. POSLOVNA INTELIGENCIJA

Pojam *business intelligence* prvi je uveo Howard Dresner 1989. godine. Od tada taj pojam postaje dio svjetskih gospodarstava bez kojeg je poslovanje nezamislivo iz razloga što je kvalitetna, točna i pravodobna informacija pretočena u poslovno znanje, podloga za poslovnu odluku i uvjet je poslovnog uspjeha. Upravo je to interes i okvir djelovanja poslovne inteligencije.

Business intelligence se u Hrvatskoj označava različitim pojmovima: poslovno izvješništvo, poslovna inteligencija, poslovno-obavještajna aktivnost, poslovno-obavijesna aktivnost, gospodarsko obavještavanje, poslovno-izvještajna aktivnost, poslovno istraživanje, upravljanje poslovnim informacijama, poslovno izvještavanje, poslovno obavješćivanje, poslovne informacije, pa, čak, i kao poslovna špijunaža i špijuniranje konkurencije (Bilandžić, 2008.).

Postoji puno definicija Poslovne inteligencije koje se razlikuju od jednog autora do drugog. Poslovna inteligencija predstavlja ranije prikriveno znanje koje se otkriva iz operativnih, rutinski prikupljenih poslovnih podataka primjenom odgovarajućih računsko-logičkih metoda, obično podržavanih informacijskom tehnologijom. (Panian, 2007.)

Poslovna inteligencija predstavlja obavještajnu aktivnost u poslovnom svijetu koju planiraju, organiziraju i provode poslovni subjekti, pri čemu ta aktivnost podrazumijeva proces legalnog prikupljanja javnih i svima dostupnih podataka etičnim sredstvima, njihovu analizu i pretvaranje u gotove poslovno-obavještajne analize ("znanje") radi pružanja potpore čelništvu poslovnog subjekta s ciljem donošenja i realizacije što kvalitetnijih poslovnih odluka usmjerenih na očuvanje postojeće pozicije poslovnog subjekta u poslovnom okruženju, izbjegavanje bilo kakvih prijetnji i u konačnici na ukupni kvalitativni napredak poslovnog subjekta. (Javorović, Bilandžić, 2007.)

Prema Gartner web stranici, Poslovna inteligencija je termin koji uključuje programe (aplikacije), infrastrukturu, alate i najbolje prakse koji omogućuju pristup i analizu podataka za poboljšanje i optimizaciju poslovnih odluka i performansi.

Kako je tipično poduzeće u mogućnosti analizirati samo 10% prikupljenih podataka, velike su šanse da im neki važni podaci promaknu i zato im je potreban sustav poslovne

inteligencije jer je to način kako iskoristiti preostalih 90% prikupljenih podataka (Luetić, 2008).

Koliko koncept poslovne inteligencije pomaže menadžmentu najbolje ilustrira podatak da tvrtke koje posjeduju i koriste se poslovnom inteligencijom bilježe rast prihoda i do 20% brže od svoje konkurencije koja ju ne primjenjuje (Luetić, 2008)

Vrlo je bitno da organizacije valjano i pravovremeno analiziraju podatke o kupcima, proizvodima, konkurenciji, financijama itd. kako bi jasnije uvidjele i razumjele probleme i mogućnosti.

Postoje 4 vrste poslovne inteligencije:

1. Agilna poslovna inteligencija (*engl. agile BI*)

Omogućuje fleksibilnost, jer ubrzava vrijeme potrebno za isporuku vrijednosti sa sustavima poslovne inteligencije. To može uključivati mogućnosti implementacije tehnologije kao što su samoposlužna poslovna inteligencija (*engl. self-service BI*), cloud bazirana poslovna inteligencija i korištenje nadzornih ploča koji omogućuju korisnicima da koriste podatke brže i prilagode se promjenjivim potrebama. Agilnost u poslovnoj inteligenciji se odnosi na aktivno korištenje sustava poslovne inteligencije i izradu izvještaja od strane većine korisnika poduzeća, a ne samo određenih grupa korisnika kao što su IT i menadžment.

Kako bi se transformirali tradicionalni načini razvoja projekata poslovne inteligencije da bi odgovarali dinamičnim zahtjevima korisnika, mnoge organizacije implementiraju formalne metodologije koje koriste agilni razvoj softvera, tehnike i alate za ubrzavanje razvoja, testiranja i implementacije. Opsežni izvještaji, povećani zahtjevi, često i temeljito testiranje i poslovna i razvojna komunikacija su važni aspekti agilnog razvoja sustava PI.

2. Memorijska poslovna inteligencija (*engl. in-memory BI*)

In-memory poslovna inteligencija se odnosi na softver koji koristi in-memory bazu podataka (IMDB). In-memory je alternativa skupom skladištenju podataka i OLAP projektima.

IMDB vrsta baza podataka koja pohranjuje podatke poslovne inteligencije kao dio skladišta podataka. Takve baze omogućuju korisnicima pokretanje upita i izvješća nad spremljenim podacima koji su redovito ažurirani i inkorporirani iz organizacijskih operativnih sustava. Osim što pružaju brzo vrijeme odaziva upita, memorijska analitika može smanjiti ili eliminirati potrebu indeksiranja i spremanje nagomilanih podataka u OLAP kocke. Navedena

sposobnost smanjuje troškove poduzeća i omogućuje bržu implementaciju aplikacija poslovne inteligencije.

3. Samoposlužna poslovna inteligencija (*engl. self-service BI*)

Sustav poslovne inteligencije u kojem krajnji korisnici dizajniraju i implementiraju vlastita izvješća i nalaze unutar odobrene i podržane arhitekture i portfelja alata.

Self service alati poslovne inteligencije omogućavaju brzu analitiku i vizualizaciju podataka te integraciju iz različitih izvora podataka.

4. Poslovna inteligencija u realnom vremenu (*engl. real-time BI*)

Pristup podacima u svrhu njihove analize koji omogućuje poslovnim korisnicima da dobiju trenutne podatke direktno pristupajući operativnim sustavima ili poslovnim transakcijama u realnom vremenu.

1.1. Infrastruktura sustava poslovne inteligencije

Sustavi poslovne inteligencije se sastoje od sljedećih komponenti: (Olszak, Ziemba 2007.)

1. ETL procesi: Skup procesa kojima je cilj ekstrahirati odnosno zahvaćati i vaditi (*engl. extract*), transformirati odnosno preoblikovati (*engl. transform*) i puniti ili unositi (*engl. load*) podatke iz jednog ili više transakcijskih sustava u skladište podataka. ETL proces započinje reformatiranjem usklađivanjem i čišćenjem izvornih podataka. Reformatiranje služi unifikaciji podataka, tj. da bi se podaci prikazivali u jedinstvenom formatu koji će se koristiti u daljnim fazama obrade.

Usklađivanje je neophodno zbog redundancije podataka odnosno pojave podataka na više mjesta u informacijskom sustavu. Često ti podaci nisu na svim mjestima jednaki i ETL procesima ih treba uskladiti.

Čišćenje podataka ima za cilj ukloniti podatke koji su nastali kao greška u radu informacijskih sustava. (Panian, Klepac 2003.)

2. Skladišta podataka – pružaju prostor za pohranu podataka koji su već skupljeni (agregirani) i analizirani. Skladišta podataka su skup podataka organizacije na kojem se temelji sustav potpore odlučivanju. Skladište podataka treba podacima potpuno „pokriti“ jedno ili više poslovnih područja (npr. nabave, prodaje), i podaci u skladištu trebaju biti sveobuhvatni, tj. „integrirani“ od unutarnjih podataka organizacije, ali i podataka iz njenog okruženja. Podaci moraju obuhvatiti duži vremenski period (pet, deset ili više godina), jer su

vremenske analize poslovno vrlo značajne. Orjentiranost prema poslovnim analizama ne zahtijeva od skladišta da se podaci promptno ažuriraju kao u bazi podataka. (Inmon, 1992. citirano prema Čerić, Varga 2004.)

U skladištu podataka najčešće se koristi dimenzijska struktura podataka. Najveća je prednost dimenzijske strukture podataka mogućnost vizualizacije podataka. U dimenzijskom modelu postoje osnovne operacije kao što su: rotacija, selektiranje, detaljiziranje i agregiranje.

Dva najzastupljenija načina modeliranja su zvjezdasta (*engl.star*) i pahuljasta (*engl.snowflake*) shema.

a) zvjezdasta struktura

Za prikaz dimenzijskog modela koristi se zvjezdasta shema (*engl.star schema*), jer dijagram izgleda kao zvijezda - jedna središnja velika tablica i skup manjih tablica s kojima je povezana ključevima. Središnja je tablica tablica s vrijednostima i naziva se tablicom činjenica (*engl.fact tabel*). Ona je jedina tablica koja je višestruko povezana s ostalim (dimenzijskim) tablicama u modelu podataka. Dimenzijske tablice (*engl.dimension table*) imaju attribute, odnosno pozicije

dimenzija i predstavljaju načine na koje možemo promatrati neku pojavu. (Ćurko, 2001.)

b) pahuljasta struktura

Za razliku od zvjezdaste sheme koja podrazumijeva da je svaka dimenzija za analizu u potpunosti denormalizirana kod pahuljaste sheme to nije slučaj, jer su hijerarhijske razine koje se nalaze u dimenzijskoj tablici normalizirane. Normalizacija i proširenje dimenzijskih tablica se vrše tako što se stupci niže kardinalnosti premještaju u posebne normalizirane tablice koje se povezuju s izvornom dimenzijskom tablicom.

3. Analitički alati (OLAP – Online Analytical processing)

OLAP se smatra "zametkom" koncepta poslovne inteligencije. Služi za izvođenje znanja iz podataka. To su alati koji se zasnivaju na metodologiji multidimenzijske analize, što znači da podatke može istovremeno promatrati kroz veći broj filtara, koji se u stručnoj terminologiji nazivaju dimenzijama. OLAP alati omogućuju obavljanje brzih analiza, a postavljanje pitanja i dobivanje odgovora se događa u vrlo kratkom roku "brzinom misli".


OLAP alati uključuju vrlo robusne sposobnosti računanja, potrebne za zadovoljavanje specifičnih proračunskih zahtjeva koje postavlja višedimenzijska struktura. Teoretski, broj dimenzija nije ničime ograničen.

Tipična OLAP arhitektura se sastoji od OLAP poslužitelja smještenog između korisnika i skladišta podataka i povezanog s njima online.

4. Data mining alati (alati za rudarenje podataka) – omogućavaju korisnicima da otkrivaju obrasce ponašanja, generalizacije i zakonitosti u izvorima podataka. Prema Čerić, Varga, 2004., Rudarenje podataka je otkrivanje znanja u bazama podataka. To je netrivialan postupak pronalaženja novih, valjanih, razumljivih i potencijalno korisnih oblika podataka. Provođi se na velikim količinama podataka iz baza podataka da bi se iz njih otkrilo novo znanje i potom iskoristilo za donošenje boljih poslovnih odluka.

5. Alati za izvještavanje i ad-hoc upite – omogućuju stvaranje i iskorištavanje izvještaja

6. Prezentacijski sloj – aplikacije koje uključuju grafička i multimedijiska sučelja čiji je zadatak pružiti korisnicima informacije u lako razumljivom i dostupnom obliku.



SLIKA 1. 1. Infrastruktura sustava poslovne inteligencije

Izvor: prilagođeno prema <http://www.information-management.com/specialreports/20020521/5211-1.html?Printable=1&nopagination=1>

Organizacije mogu ostvariti konkurentusku prednost sa dobro dizajniranim sustavom poslovne inteligencije koji se sastoji od nekoliko slojeva (slika 1.1).

Integracija podataka – dana integration

Sloj za integraciju podataka je odgovoran za pročišćavanje, transformaciju i spremanje podataka u skladište podataka. Ovaj sloj započinje sa transakcijama na razini operativnih podataka i meta podataka. Integracija podataka se obavlja pomoću relacijskih baza. Rezultat integracije bi trebao biti visoka kvaliteta podataka, ponovno upotrebljiva infrastruktura i meta podaci koji jednako podupiru tehničke i poslovne korisnike. Ovaj sloj će generirati meta podatke koji moraju biti spremljeni i korišteni i u ostalim slojevima kako bi se osigurala pravilna isporuka, podrška i smjernice za administratore sustava i korisnike sustava poslovne inteligencije.

Skladište podataka

Skladište podataka je sloj koji se sastoji od relacijskih i / ili OLAP usluga koje omogućuju poslovnim korisnicima da steknu uvid u svoja područja odgovornosti u organizaciji. Razvija se postupno tijekom vremena i projektirano je tako da uključuje ključne poslovne varijable i poslovne podatke u strukturu koja odgovara na sva pitanja poslovne analize potrebne od strane poslovnih grupa.

Da bi se skladište podataka ispravno dizajniralo, potrebno je definirati poslovne zahtjeve i ključna poslovna pitanja.

Ključna područja koja treba razmotriti pri definiranju zahtjeva su povezana s glavnim funkcijama u organizaciji – kupci, operativna i poslovna inteligencija na zahtjev.

Korisnička inteligencija (*engl. customer intelligence*) se odnosi na kupca, usluge, prodaju i marketinške informacije promatrane kroz neko vremensko razdoblje, geografski položaj/lokaciju, proizvod ili kupca.

Operativna inteligencija (*engl. operational intelligence*) se odnosi na financiranje, operacije u proizvodnji, distribuciju, logistiku i ljudski izvor informacija koji su promatrani kroz neko vremensko razdoblje, lokaciju, proizvod, projekt, dobavljača, zaposlenika, itd.

Poslovna inteligencija na zahtjev (*engl. clickstream intelligence*) se odnosi na web sjedište, prodaju i servisne informacije promatrane kroz neko vremensko razdoblje, proizvod, kupca, web stranice i prema vrsti zahtjeva.

Aplikacije poslovne inteligencije

To je najvidljiviji sloj sustava poslovne inteligencije koji donosi informacije poslovnim korisnicima. Zahtjevi poslovne inteligencije uključuju izvješće proizvodnje i distribucije, upite i analize koji otkrivaju trendove u poslovanju. Ovaj sloj omogućuje korisnicima interakciju s informacijama pomoću kojih mogu dobiti uvid u temeljne poslovne varijable za podršku donošenja poslovnih odluka. Druga važna primjena je balanced scorecard koji pokazuje ključne pokazatelje uspješnosti i ciljeve za kupce, interne sustave i ljudski kapital.

Web portali

Predstavljanje poslovne inteligencije putem Weba dobiva sve veći značaj. Web portali postaju uobičajena mjesta personaliziranih pristupa ključnih pokazatelja poslovanja. Portali

su organizirani prema grupama korisnika: dobavljači, kupci, zaposlenici i partneri i svi veći dobavljači poslovne inteligencije imaju svoje portale. Portali mogu smanjiti ukupne troškove infrastrukture za organizaciju i dostaviti odlične usluge za korisnika te im pružiti informacije.

Organizacijski zahtjevi

Postoji nekoliko organizacijskih promatranja koja doprinose učinkovitoj strukturi poslovne inteligencije. Prvo je imati temeljnu implementaciju poslovne inteligencije i tim podrške koji je zadužen za optimizaciju poslovne inteligencije, odnosno njezine infrastrukture.

Treba postojati organizacijska podrška za sustav poslovne inteligencije i objektivne mjere za praćenje učinkovitosti tog sustava. Te mjere trebaju uključiti područja kao što su korištenje sustava poslovne inteligencije, ocjena poslovnih i meta podataka, ocjena razine usluge i ocjena učinkovitosti sustava.

1.2. Razvoj sustava poslovne inteligencije

Projekti za izradu sustava poslovne inteligencije su organizirani u skladu sa 6 faza koji su zajednički svakom inženjerskom procesu. Unutar svake od 6 faza, nalaze se još i podfaze koje vode do završetka procesa. Prema knjizi Moss i Altre, „Business Intelligence Roadmap“ prikazano je 16 razvojnih koraka izrade sustava poslovne inteligencije.

1. Faza: faza opravdanja projekta (*engl. The Justification Stage*)

Korak 1. Procjena poslovnog slučaja

Nakon definiranja poslovnog problema ili poslovne prilike, predloženo je rješenje poslovne inteligencije. Svako rješenje sustava poslovne inteligencije treba biti troškovno opravdano s jasno definiranim prednostima za rješavanje poslovnog problema ili preuzimanje poslovne prilike.

2. Faza: faza planiranja (*engl. Planning*)

*Korak 2. Procjena infrastrukture poduzeća (*engl. Enterprise Infrastructure Evaluation*)*

Sustavi poslovne inteligencije se protežu kroz cijelu organizaciju i one trebaju biti organizirane da podupiru poslovnu inteligenciju. Neka infrastruktura organizacije je „postavljena“ prije uvođenja sustava poslovne inteligencije, a neki dijelovi infrastrukture se

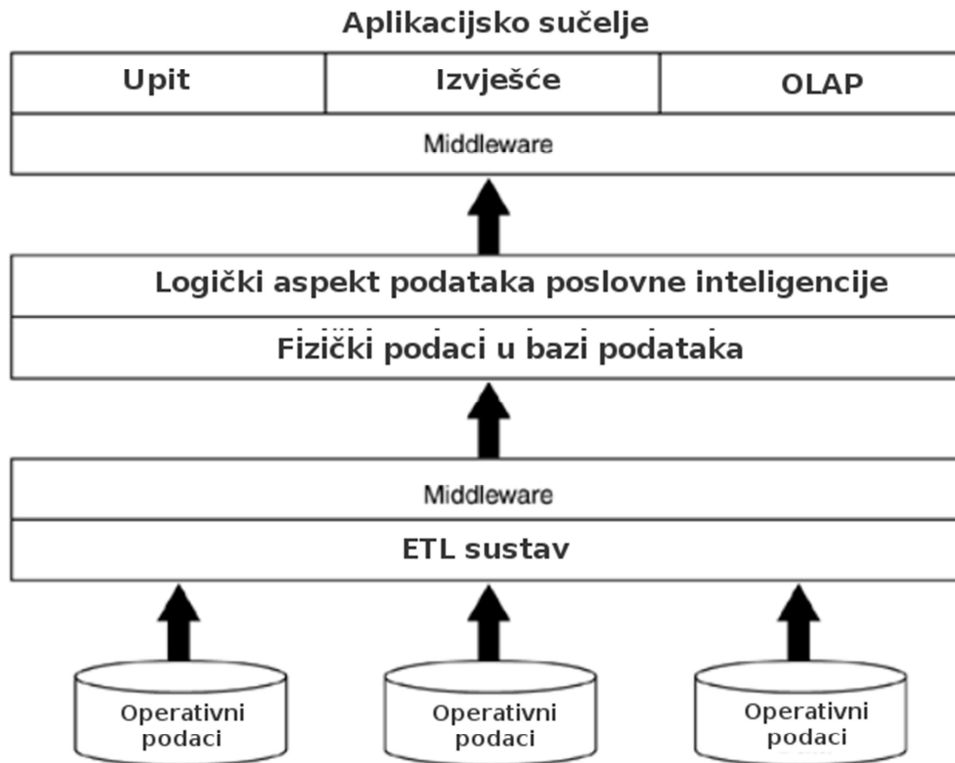
razvijaju usporedno sa sustavima poslovne inteligencije. Infrastruktura poduzeća se sastoji od tehničke i netehničke infrastrukture.

Tehnička infrastruktura uključuje hardver, softver, middleware, sustave za upravljanje bazama podataka, operacijske sustave, mrežne komponente itd. Za izradu adekvatnih izvješća i za postavljanje upita, najvažnije je imati dovoljno memorije na hardverskoj platformi. Skalabilnost¹ je najbitnija.

Hardverska platforma se sastoji od 3 razine računalne arhitekture:

1. ETL sustav pročišćava, transformira i sprema podatke.
2. Zatim se uz pomoć middleware-a, popunjavaju ciljne baze podataka
3. Na kraju, kada su podaci spremljeni, koriste se na razini sučelja za pokretanje upita, izvješća i OLAP-a. Sučelje može biti prilagođeno grafički, kao aplikacija ili na razini web servisa (XML).

¹ Pojam skalabilnosti označava sposobnost sustava da se prilagodi promjenama opterećenja tako da obilježje dostupnosti i pouzdanosti ostane o čuvano. Drugim riječima, povećano opterećenje skalabilnog sustava neće rezultirati smanjenjem njegovih performansi.



SLIKA 1. 2. Tehnička infrastruktura.

Izvor: prilagođeno prema: Moss, Atre: Business intelligence roadmap, 2008, str. 89

Middleware se odnosi na softver koji se nalazi između aplikacije i operacijskog sustava. Middleware je nužna stavka za pokretanje klijentsko-poslužiteljske arhitekture i ostalih složenih umreženih arhitektura u distribuiranom računalnom okruženju.

Middleware se dijeli u 2 osnovne kategorije:

1. Distribuirana logika koja podržava program – program komunicira između dva dijela aplikacijskog koda.
2. Middleware za upravljanje podacima koji povezuje aplikacije ili DBMS na jednoj platformi sa DBMS pokrenut na drugoj platformi.

Ne-tehnička infrastruktura uključuje standarde za upravljanje podacima, standarde za imenovanje podataka, logičke modele podataka, procedure testiranja, procese kontrole, pitanja za upravljanje i rješavanje sporova itd.

Izrada ne-tehničke infrastrukture uključuje organizacijske aktivnosti navedene u nastavku:

1. Provođenje opsežne analize poslovanja koja uključuje poslovne ljude iz različitih aspekata poslovanja.
2. Usvajanje sustava stručne procjene za podršku organizaciji i procjenu analize poslovnih aktivnosti.
3. Rješavanje starih sporova oko definicije podataka.
4. Standardiziranje imena podataka i vrijednosti podataka tako da odgovaraju stvarnim poslovnim pravilima i poslovnoj politici.
5. Stvaranje redovitog sastanka na kojemu će se obaviti nadzor standarda, poslovnih pravila i poslovne politike.
6. Stvaranje konsolidirane neredundantne arhitekture podataka za cjelokupno poduzeće da odražava stvarnu složenost poslovanja, tj. stvoriti logički model podataka poduzeća.
7. Stvaranje repozitorija meta podataka i ispunjavanje sa neredundantnim meta podacima.
8. Izrada popisa izvora podataka i mapiranje na bazama podataka sustava poslovne inteligencije. Isto tako, potrebno je stvoriti popis ostalih komponenti sustava kao što su programi, izvješća, praćenje u svrhu identifikacije ponovnog korištenja podataka i dijelova procesa.
9. Stvaranje i upravljanje širim područjem za prikupljanje podataka i ETL procese.

Korak 3. Planiranje projekta (engl. Project Planning)

Projekti za uspostavljanje sustava poslovne inteligencije su vrlo dinamični. Promjene zaposlenika, budžeta, predstavnika tvrtki i sponzora, mogu utjecati na uspješnost projekta. Stoga planiranje mora biti detaljno, a stvarni napredak mora biti detaljno promatran i bilježen.

3. Faza: faza poslovne analize (engl. The Business Analysis Stage)

Korak 4. Analiza zahtjeva projekta (engl. Project Requirements Definition)

Upravljanje opsegom projekta je najteži dio uspostavljanja sustava poslovne inteligencije. Projektni timovi trebaju biti spremni na promjene zahtjeva tokom implementacije PI, a

korisnici koji će koristiti sustav PI će tijekom faze implementacije naučiti o mogućnostima i ograničenjima tehnologije koju koriste takvi sustavi.

Korak 5. Analiza podataka (engl. Data Analysis)

Najveći izazov tijekom uspostave sustava poslovne inteligencije je pronaći kvalitetan izvor podataka. Loše navike prikupljanja podataka koje su stvarane desetljećima, teško je razbiti, a šteta proizašla iz takvih navika je skupa, dugotrajna za pronalaženje i ispravljanje. Analiza podataka je u prošlosti bila ograničena na prikaz samo jedne djelatnosti unutar organizacije te nije uzimala u obzir i ostale djelatnosti.

Postoje 3 vrste izvora podataka: operacijski (*engl. operational*), privatni (*engl. private*) i vanjski (*engl. external*). Spajanje i standardizacija podataka je zahtjev svakog sustava PI. Prilikom tog procesa stvaraju se problemi standardizacije podataka iz različitih izvora i podaci koji su pohranjeni u različite strukture na različitim platformama. Ovaj korak oduzima značajan postotak vremena dodijeljenog cijelom projektu.

Korak 6. Izrada prototipa aplikacije (engl. Application Prototyping)

Analiza funkcionalnosti se najbolje može napraviti uz izradu prototipa i može se kombinirati i sa dizajnom aplikacije. Novi alati i programski jezici omogućuju programerima da vrlo brzo potvrde da li je koncept dobar ili nije. Prototipiranje omogućuje korisnicima da vide mogućnosti i ograničenja tehnologije i da zajedno sa programerima prilagode svoje zahtjeve i očekivanja.

Korak 7. Analiza repozitorija meta podataka (engl. Meta Data Repository Analysis)

Što se više alata koristi, bit će i veći broj tehničkih meta podataka uz poslovne meta podatke. Tehničke meta podatke treba mapirati uz poslovne meta podatke, a svi zajedno meta podaci trebaju biti pohranjeni u repozitorij meta podataka. Repozitorij meta podataka je baza podataka, ali nešto drugačija od uobičajenih transakcijskih baza. U njoj se ne pohranjuju poslovni podaci koje generiraju poslovne aplikacije, već kontekstualne informacije o poslovnim podacima. Spremišta meta podataka mogu biti kupljena uz licencu ili mogu biti izgrađena unutar organizacije. Zahtjevi za vrstama meta podataka koji trebaju biti spremljeni trebaju biti dokumentirani u logičkom meta modelu.

4. Faza: faza dizajna (engl. *The Design Stage*)

Korak 8. Dizajn baze podataka (engl. Database Design)

Jedna ili više baza podataka koje koristi sustav poslovne inteligencije će pohraniti podatke u detaljnom ili zbirnom obliku, ovisno o zahtjevima za izvještavanje koje koriste organizacije ili poslovne zajednice. Dizajn baze podataka mora odgovarati zahtjevima za pristup informacijama poslovne zajednice. Kod učitavanja podataka u skladište vrši se denormalizacija i optimizacija podataka za analitičke upite.

Korak 9. Pročišćavanje, transformacija i punjenje podataka (engl. Extract/Transform/Load Design)

ETL process je najsloženiji proces cjelokupnog projekta sustava poslovne inteligencije. Proces ETL počinje s pripremama za formatiranjem, usklađivanjem i čišćenjem izvornih podataka. Postavke ETL procesa možemo podijeliti u 3 dijela:

- **Inicijalno punjenje** – punjenje baza podataka trenutnim operativnim podacima
- **Povijesno punjenje** – punjenje baze podataka sa arhiviranim povijesnim podacima.
- **Inkrementalno punjenje** – konstantno ažuriranje baze podataka trenutnim operativnim podacima.

Korak 10. Dizajn skladišta meta podataka (engl. Meta Data Repository Design)

Ako je skladište meta podataka licencirano morat će biti pojačano sa značajkama logičkog meta modela, a te značajke nema samo skladište. Ako organizacija sama gradi meta skladište podataka, tada je potrebno odlučiti da li će dizajn meta skladišta podataka biti entitet-veza (*engl.entity-relationship*) ili objektno orijentirano. U svakom slučaju, dizajn mora zadovoljiti zahtjeve logičkog meta modela.

Postoje 2 vrste meta podataka:

- *Poslovni meta podaci* – pružaju poslovnim korisnicima smjernice za pristupanje poslovnim podacima u okruženju donošenja odluka pomoću sustava poslovne inteligencije. Poslovni korisnici većinom ne razumiju tehničke pojmove i stoga bi oni trebali imati pristup meta podacima u poslovnom okruženju kojeg razumiju.
- *Tehnički meta podaci* – podržavaju tehničare i ostale napredne korisnike pružajući informacije o aplikacijama i bazama podataka koje oni zahtijevaju u skladu sa aplikacijama poslovne inteligencije.

5. Faza: faza izgradnje (engl. *The Construction Stage*)

Korak 11. Razvoj procesa pročišćavanja, transformacije i punjenja podataka (engl. Extract/Transform/Load Development)

Ovisno o zahtjevima za čišćenje i transformaciju podataka koji su se razvili tokom 5.koraka – analiza podataka i koraka 9. Ekstrahiranje, transformacija i punjenje podataka, ETL alati mogu, ali ne moraju biti najbolje rješenje. Predobrada podataka i pisanje dodataka za nadopunu mogućnosti ETL alata, često je potrebno.

Korak 12. Razvoj aplikacije (engl. Application Development)

Nakon što je prototip nadopunio funkcionalne zahtjeve, stvarni razvoj aplikacije može započeti. Razvoj aplikacije može biti samo finaliziranje prototipa ili razvoj može teći u drugačijem smjeru uz robustan pristup. Front-end razvoj se koristi paralelno sa back-end ETL razvojem i razvojem skladišta meta podataka.

Korak 13. Rudarenje podataka (engl. Data mining)

Mnoge organizacije ne koriste sustave PI u njihovom punom kapacitetu. Pravo iskorištenje sustava PI dolazi od informacija skrivenih u podacima organizacije, a oni mogu biti otkriveni pomoću alata za rudarenje podataka..

Korak 14. Razvoj skladišta meta podataka (engl. Meta Data Repository Development)

Ukoliko organizacija donese odluku da se skladište meta podataka napravi unutar organizacije, tada se angažira poseban tim za razvoj. Projekt razvoja skladišta meta podataka je poveliki pothvat u odnosu na cijeli projekt razvoja PI.

6. Faza: fazovna faza (engl. *The Deployment Stage*)

Korak 15. Implementacija

Nakon što su testirane sve komponente sustava PI, dolazi do implementacije baze i aplikacije. Nakon toga, zaposlenici koji će se koristiti aplikacijom PI i skladištima podataka, moraju pohađati edukaciju. Aktiviraju se funkcije podrške koje uključuju: operativnu pomoć, održavanje baze podataka i ETL procese.

Korak 16. Puštanje sustava u upotrebu (engl. Release Evaluation)

Nakon puštanja sustava poslovne inteligencije u rad, vrlo je važno pratiti projekt te ispraviti pogreške koje se javljaju tokom rada. Alati, smjernice i procesi koji nisu bili od koristi, potrebno je ponovno vrednovati i prilagoditi pa čak neke i odbaciti.

Poslovna inteligencija objedinjuje podatke, tehnologiju, analitiku i ljudsko znanje za optimiziranje poslovnih odluka i u konačnici dovodi do uspjeha poduzeća. Sustavi poslovne inteligencije kombiniraju skladišta podataka i platformu sustava poslovne inteligencije ili skup alata kako bi transformirali podatke u korisne i djelotvorne poslovne informacije.

1.3. Dobavljači sustava poslovne inteligencije

Dresner centar za istraživanja, 2013. godine dijeli dobavljače sustava poslovne inteligencije u 6 skupina:

Titani (Titans) – najveći dobavljači s dugogodišnjom tradicijom (IBM Cognos, Microsoft, Oracle, Infor i SAP). Njihove baze služe kao temelj za izgradnju skladišta podataka. Tu platformu oni koriste kao osnovicu. Klijentima također nude i front-end alate za krajnjeg korisnika kao i implementaciju i poslovne modele. Najčešće im fokus nije samo na poslovna inteligencija nego su vodeći na velikom broja polja informacijske tehnologije.

Veliki specijalizirani dobavljači (*engl. Large Established Pure-Play*) – dobavljači poslovne inteligencije koji se bave isključivo kreiranjem softvera poslovne inteligencije, s poslovnim iskustvom od 15 ili više godina (Information Builders, MicroStrategy, QlikTech and SAS Institute). Njihov glavni fokus su front-end alati za krajnje korisnike koji se mogu vezati na bilo koju od platformi za bazu podataka.

Specijalizirani dobavljači (*engl. Specialized*) – dobavljači koji se bave sustavima poslovne inteligencije 10 ili više godina i fokusiraju se na specifične tržišne segmente ili industrije (Dimensional Insight, Dundas, Panopticon and Phocus).

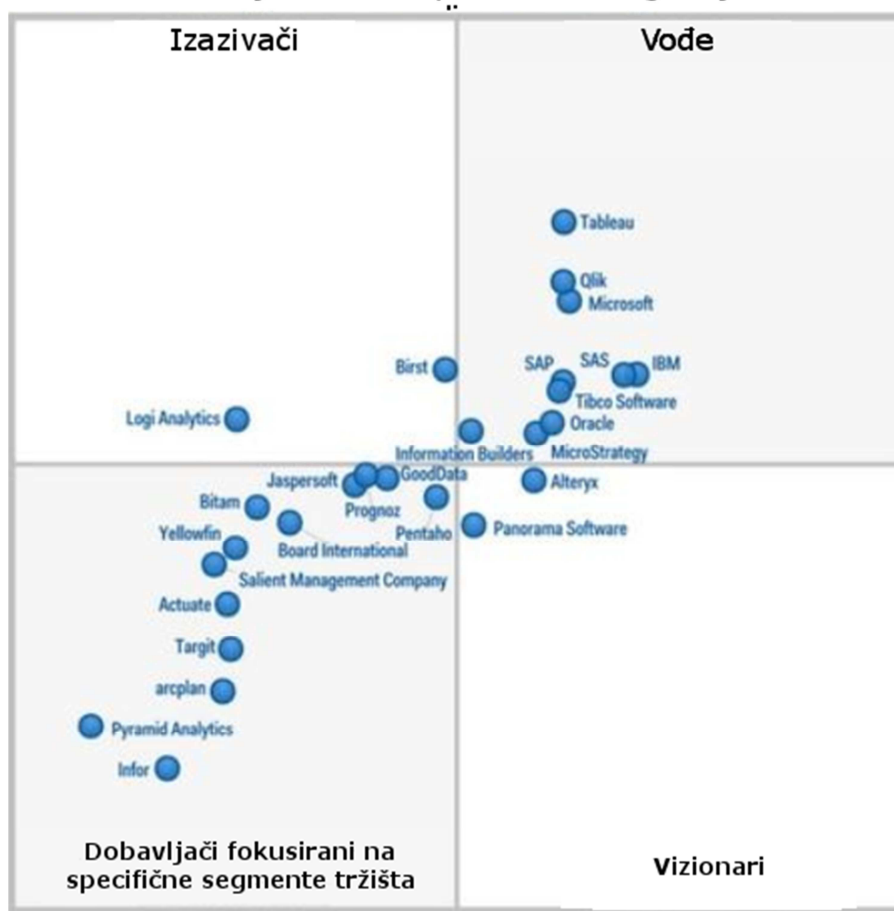
Visoko rastući (*engl. High Growth*) – dobavljači koji su dostigli kritičnu masu na tržištu i nastavljaju rasti po iznimno velikoj stopi rasta (Tableau, Tibco Spotfire, Pentaho and LogiAnalytics).

Dobavljači u nastajanju (engl. *Emerging*) – dobavljači koji su mlađi od ostalih, ali nude jedinstvene i često inovativne poslovne modele, tehnologije ili servise (Jedox, Jaspersoft, Birst, iDashboards and Yellowfin).

Dobavljači u ranoj fazi (engl. *Early Stage*) – najmlađe tvrtke dobavljači sustava poslovne inteligencije.

Prema istraživanju Gartner stranice iz veljače 2014. godine, postoji 10 dobavljača koji su vodeći: Oracle, IBM, Microsoft, Tableau, Qlik, SAP, SAS, MicroStrategy, Tibco spotfire, Information builders dok su izazivači Birst i Logi Analytics.

Vodeći dobavljači sustava poslovne inteligencije 2014.



SLIKA 1. 3. Dobavljači sustava poslovne inteligencije

Izvor: <http://www.informationweek.com/big-data/big-data-analytics/gartner-bi-magic-quadrant-winners-and-losers/d/d-id/1114013> (30.4.2014.)

1.4. Budućnost poslovne inteligencije

TDWI, 2014. nam opisuje 5 trendova poslovne inteligencije koji će se pojaviti u 2014. godini.

1. Tvrtke se hvataju u koštac s nestrukturiranim podacima

Pretraživanje postaje srž poslovne inteligencije. Većina sustava poslovne inteligencije obavlja samo jednu vrstu pretrage – predefinirane upite nad relacijskim bazama podataka. TDWI navodi kako to više nije dovoljno iz razloga što je netko iz iste tvrtke već obavio analizu tih istih podataka.

Zbog toga što nisu svi podaci pohranjeni u relacijskim poljima, suvremeni sustavi poslovne inteligencije trebaju pristup i strukturiranim i nestrukturiranim podacima. Jedna stvar je analiza, tablica i teksta, a jedna sasvim drugačija je analiza novinskih članaka, web sadržaja, socijalnih mreža, emailova i ostalih podataka koji se nalaze izvan SQL baza podataka.

Sustavi poslovne inteligencije već čine velike korake u pristupu nestrukturiranim podacima, a 2014. godina će biti ključna godina jer organizacije žele pristup informacijama. Primjer za to je zdravstvo gdje postoji velika količina podataka u obliku rukom ispisanih recepata, dijagnostičkih rezultata itd., a poslovna inteligencija mora biti u mogućnosti obrađivati i takve vrste podataka.

2. Pretraga će se dramatično poboljšati

Tradicionalna pretraga je bazirana na tome da pretražuje prema ključnim riječima. Pretraga budućnosti neće samo pretraživati prema ključnim riječima nego će uključivati i pretraživanje prirodnog jezika te autoklasifikacija podataka kroz tagove i filtere. Koristeći specifičnu industrijsku ontologiju za poboljšanje rezultata pretrage temeljenih na semantičkoj analizi sadržaja pomaže se organizacijama da pristupe samo onim relevantnim informacijama koje su im potrebne za donošenje odluka.

3. Mobilnost će postati dvosmjerna

Danas je mobilna poslovna inteligencija bitna komponenta bilo kojeg analitičkog rješenja. Prve mobilne aplikacije su omogućavale korisnicima pregled podataka na daljinu pomoću pametnih telefona, a kako su se aplikacije i uređaji usavršavali, korisnicima je postalo lakše pristupiti informacijama koje su im potrebne.

U budućnosti će biti važno pristupati podacima, dodavati ih i mijenjati ih bez obzira na mjesto na kojem se nalazimo.

Sposobnost aplikacija PI da djeluje na podatke odmah je ključno i okreće poslovnu inteligenciju u stvarnu poslovnu korist.

4. Tvrtke moraju znati s velikom količinom podataka (engl. Big Data)

Organizacije svakodnevno primaju velike količine podataka koje moraju biti sposobne brzo i točno analizirati, a velik dio tih podataka je nestrukturiran. Organizacije te podatke moraju biti u mogućnosti analizirati odmah i ne čekati punjenje baza podataka. Vremena se mijenjaju te oni podaci koji su se nekad obrađivali satima, sada trebaju biti obrađeni u nekoliko minuta.

5. Dobavljači sustava poslovne inteligencije su svjesni da njihovi alati moraju konstantno raditi, biti brzi i jednostavni

Aplikacije se trebaju instalirati brzo i jednostavno (cloud rješenja), a korisnici ne trebaju prolaziti duge edukacije. Poduzeća ulažu u aplikacije koje ne zahtijevaju dugoročnu implementaciju i edukaciju korisnika. Danas, prodavači ne prodaju, već kupac kupuje korisničko iskustvo koje donosi najveću vrijednost na najbrži mogući način.

1.5. Primjena poslovne inteligencije u Hrvatskoj i svijetu

Prema istraživanju Bilandžić, Čulig, Lucić, Putar-Novoselec i Jakšić, 2011., provedenom na uzorku od 1000 najvećih tvrtki u Hrvatskoj, pokazano je da je pojam poslovne inteligencije još uvijek nepoznanica u Hrvatskoj. Istraživanje je pokazalo da poslovna inteligencija nije jednako zastupljena u svim regijama niti djelatnostima te da je zastupljenija u velikim tvrtkama i tvrtkama koje sebe smatraju konkurentnijima na tržištu.

57% tvrtki primjenjuje neke od aktivnosti poslovne inteligencije, a samo njih 19% ima odjel koji se bavi aktivnostima poslovne inteligencije. Najveći broj tvrtki koje imaju institucionalizirani odjel poslovne inteligencije (78%) se nalazi na području Sjeverozapadne Hrvatske, dok se u južnoj regiji nalazi najveći broj tvrtki (31%) koje ne primjenjuju ni jedan oblik aktivnosti poslovne inteligencije.

Aktivnostima poslovne inteligencije najviše se služe tvrtke u sektoru bankarstva i financija (84%) te u sektoru informacija i komunikacija (82%).

U svijetu je situacija drugačija. Istraživanje je provedeno od strane Dresner Advisory centra 2013. godine. Svijet je podijeljen u regije: Sjeverna Amerika, Europa, Bliski Istok i Afrika , Azija i Latinska Amerika. Najveći korisnici poslovne inteligencije su tvrtke iz Sjeverne Amerike sa 20% poduzeća koja imaju implementiranu poslovnu inteligenciju koju koristi 81 % njihovih zaposlenika. Zatim slijedi regija Europa, Bliski Istok i Afrika sa 17% tvrtki koje imaju implementiranu poslovnu inteligenciju koju koristi 80% zaposlenika u tim tvrtkama. U Aziji 15 % poduzeća ima implementiran sustav poslovne inteligencije, a u Latinskoj Americi samo 8%.

Sustavima poslovne inteligencije se najviše koristi izvršni menadžment i IT stručnjaci, a kao najveća prednost korištenja sustava poslovne inteligencije, korisnici navode brže donošenje odluka i povećanu učinkovitost. (Yellowfin, 2013.)

2. SUSTAVI MOBILNE POSLOVNE INTELIGENCIJE

Mobilna poslovna inteligencija je najjednostavnije rečeno primjena poslovne inteligencije na mobilnim uređajima i tabletima. Kako u današnje vrijeme, pogotovo u poslovanju, postoji velika potreba za pristupom informacijama u svakom trenutku i na svakom mjestu, došlo je do razvoja mobilne poslovne inteligencije koja upravo to nudi. Mobilna poslovna inteligencija (skraćeno MPI) omogućuje brže donošenje poslovnih odluka u realnom vremenu.

MPI može pružiti sve što i PI, ali nije riječ samo o replici sustava poslovne inteligencije na mobilnim uređajima. Postoje i jedinstvene značajke sustava MPI kao što su dodirni zaslon i otkrivanje geo-lokacije koje onda omogućuju intuitivnu vizualizaciju i upozorenja i podsjetnike temeljene na lokaciji.

Korisnici MPI imaju drugačija očekivanja od korisnika tradicionalne, odnosno desktop PI. Oni su izuzetno osjetljivi na vrijeme i traže veću personalizaciju i intuitivnu vizualizaciju.

TABLICA 2. 1. Značajke MPI

<i>Nadzorne ploče</i>	<i>Svrđlanje podataka</i>	<i>Push izvještavanje</i>
Upozorenja i izvještavanje	Ad-hoc upiti i izvještavanje	<i>Pristup skladištima i bazama podataka</i>
OLAP funkcionalnosti	Analiza mogućnosti	Napredna analiza
Mogućnost ažuriranja	Dijeljenje između grupa korisnika	<i>Mogućnost komentiranja na izvještajima i nadzornim pločama</i>

Izvor: Mobile Business Intelligence: Intelligence at the Fingertips, School of Management Studies, University of Hyderabad, Hyderabad, str. 371.

MPI proizlazi iz promjena u prirodi odlučivanja koje su se dogodile tijekom vremena:

1. menadžeri su povećali svoju pokretljivost zbog promjena u načinu na koji se podaci procesiraju i dijele izvan organizacija uključujući i decentralizaciju ureda i upravljanje na različitim lokalnim i globalnim lokacijama.
2. zajednička odlučivanja između multikulturalnih i multidisciplinanih skupina za donošenje boljih odluka

3. današnji poslovni modeli se oslanjaju na mobilne usluge iz tehničke perspektive (promicanje mobilne kulture putem e-maila na mobitelima i ostalih mobilnih aplikacija) te ljudske perspektive (zahtijeva se veća mobilnost radnika te je potrebna njihova stalna dostupnost).

- **Zašto odabrati MPI?**

Prema istraživanju Pulipati sa Sveučilišta u Hyderabad-u menadžeri koji donose odluka pomoću mobilne poslovne inteligencije rade to za 2/3 brže nego menadžeri koji ne koriste MPI, a ostale prednosti su: povećanje konkurentske prednosti, poslovne agilnosti, produktivnosti zaposlenika, prodaje i profitabilnosti, zadovoljstva korisnika i njihove lojalnosti, dijeljenja znanja i suradnje na poslu, donošenje odluka na bilo kojem mjestu i u bilo koje vrijeme i povećana usluga korisnicima (*engl. customer service*) i funkcije podrške (*engl. support functions*).

2.1. Povijesni razvoj mobilne poslovne inteligencije

Nemoguće je zanemariti „eksploziju“ tržišta mobilnih uređaja. Stručnjaci predviđaju da će do 2020. Godine biti oko 10 milijardi mobilnih uređaja – 10 puta više nego ljudi trenutno koriste osobna računala za pristup Internetu. (Stanley, 2009.)

Upotreba mobilnih uređaja revolucionalizira kako, kada i gdje su informacije korištene i odluke donesene.

Od 1960.godine pojavila su se 4 ciklusa računalstva:

1. **Osnovno računalstvo**
2. **Mini računalstvo**
3. **Osobno računalstvo (PC)**
4. **Desktop računalstvo**

Mobilno računalstvo je peti tehnološki ciklus u posljednjih pola stoljeća. Mobilni pristup informacijama će u bliskoj budućnosti zasjeniti pristup informacijama preko desktop računala i to će dovesti do nove ere poslovne inteligencije. Poslovna inteligencija na mobilnim uređajima, tabletima i pametnim telefonima ima potencijal da revolucionalizira poslovne procese.

Predviđa se da će peti ciklus imati veći utjecaj od svih dosadašnjih ciklusa zajedno.

Danas su tableti i pametni telefoni općeprihvaćeni iz nekoliko razloga: konstanto su spojeni na Internet, jednostavni su za prenošenje te ih je lako koristiti.

U bliskoj prošlosti, laptopi su omogućili mobilnost te pomaknuli granice sa klijentsko-poslužiteljske arhitekture do web bazirane arhitekture. Prve mobilne aplikacije su predstavljene 2005.godine kada je prvi puta omogućen pristup Internetu putem mobitela. Tada su korisnici mogli pristupati web baziranim izvještajima i analizama. Preglednici su imali samo osnovne funkcije pa ponekad nisu niti podržavali grafove, izvještaje i tablična izvješća, a i onda kada se se mogli otvoriti, bilo ih je teško tumačiti na malim ekranima.

Otpribliže u isto vrijeme se pojavila mogućnost "pusha" poslovnih podataka (najčešće u tekstualnom obliku) na mobilne uređaje korisnika. Iako su tada podaci postali dostupni i u pokretu, količina podataka koja se mogla prikazivati na tadašnjim mobilnim uređajima je bila ograničena. Takav pristup je korisnicima samo pružao upozorenja, ali ne i interakciju s podacima pomoću kojih se mogu donositi poslovne odluke.

Daljnja evolucija mobilne poslovne inteligencije je bila takva da se moglo pristupati tablicama podataka putem web preglednika, ali zbog ograničenosti prve generacije web preglednika, taj pristup je bio ograničen i spor, a ekrani mobilnih uređaja su bili premali.

Pojavom iPhone-a, iPad-a, Android telefona i tableta u potpunosti se promijenio način na koji ljudi koriste podatke na mobilnim uređajima, što je dovelo i do razvoja aplikacija MPI koje su korištene za pretvorbu izvještaja i podataka u mobilne nadzorne ploče (*eng. dashboards*) koje su se odmah prosljeđivale na pametne telefone. MPI aplikacije prvo su bile korištene isključivo za pregled podataka, a do danas su se razvile u aplikacije izgrađene sa posebnom svrhom za pružanje i analizu informacija i njihov prikaz u korisniku odgovarajućem obliku, a neophodne su za brzo donošenje odluka i poduzimanje akcija.

Prodaja smartphone-a i tableta kontinuirano raste, a do 2015. godine se predviđa da će biti do 7,4 milijarde uređaja koji se mogu spojiti na bežični Internet (*engl.wireless*), a kroz sljedećih 5 godina se predviđa da će se pojaviti oko 1,2 milijarde novih smartphone-a na tržištu. (Forbes, 2012.)

Mobilni uređaji su na dobrom putu da zamijene kamere, novac, kalkulatore, bilježnice i još puno toga pa se javlja pitanje što mobilni uređaji ne mogu, a ne što mogu.

Dok su mogućnosti mobilnih poslovnih aplikacija beskonačne, cilj je uvijek isti: opskrbiti zaposlenike, partnere i kupce/korisnike sa pravovremenim (*engl. real-time*) i relevantnim informacijama koje unapređuju poslovanje.

2.2. Prednosti i nedostaci MPI

2.2.1. *Prednosti MPI*

Povećana produktivnost zaposlenika

Zaposlenici koji ne mogu pristupiti podacima u svrhu odlučivanja, nisu toliko efikasni i uspješni u odlučivanju kao oni koji mogu pristupiti podacima. Omogućavanje neometanog pristupa podacima i analiza putem mobitela omogućuje optimalnu razinu produktivnosti pa čak i kada su izvan ureda.

Poboljšana agilnost

Mobilna poslovna inteligencija omogućuje donositeljima odluka da budu trenutno upozoreni o događajima te tako odmah mogu pristupiti rješavanju problema. NASA npr. koristi MPI za upozorenja o nadolazećim nepogodama.

Pojačana suradnja

MPI je jedan od najučinkovitijih načina za organizacije da koordiniraju i dijele informacije interno, kao i sa trećim stranama s kojima posluju, npr. dobavljačima.

Povećano zadovoljstvo kupaca/korisnika

Sve više tvrtki omogućuje dostupnost informacija kupcima u obliku samoposlužnih (*engl. self-service*) aplikacija poslovne inteligencije. Kako bi navedene aplikacije bile uspješne, trebaju biti intuitivne i praktične u što većoj mjeri. Proširivanjem izvještavanja na mobilnim uređajima, koja su dostupna kupcima, tvrtke mogu povećati zadovoljstvo i lojalnost kupaca.

Revolucionarnom utjecaju mobilne poslovne inteligencije svjedoče 3 glavne karakteristike:

- Mobilna poslovna inteligencija proširuje korisničku populaciju
- Proširuje mogućnosti informacija (npr. prema mjestu gdje se nalazimo)
- Povećana personalizacija upita

2.2.2. Nedostaci MPI

Sigurnost podataka i privatnost su najveće barijere organizacija koje žele uvesti sustav mobilne poslovne inteligencije. Postoje prijetnje i u tradicionalnim oblicima poslovne inteligencije kao što su krađa podataka i virusi, ali oni imaju veću težinu u mobilnom okruženju. Obzirom na osjetljivost podataka i uključeni rizik otuđenja mobilnog uređaja, organizacije su skeptične u vezi uvođenja sustava MPI. Sigurnosni i problemi privatnosti podataka mogu biti umanjeni uz pomoć projektiranja u skladu sa sigurnosnim standardima, više slojeva autentifikacije korisnika i uvođenje ograničenih sesija. Implementacija enkripcije podataka za osjetljive podatke, izbjegavanje pohranjivanja podataka na mobilnim uređajima (uz iznimku ako je to neophodno), izbjegavanje nesigurnih operativnih sustava i poštivanje načela privilegija, samo su neke od mjera kojima se može osigurati sigurnost i privatnost.

Nedovoljan budžet i stručno osoblje su također prepreke uvođenju MPI. Također, važno je i poznavati povrat ulaganja (*engl. return of investment*) MPI. U nedostatku konkretnih izračuna povrata ulaganja, vrlo je teško objasniti utjecaje MPI na informacijske i na programe za podršku odlučivanju. Usvajanje i razina upotrebe sustava je jedan od načina ocjenjivanja uspjeha implementacije MPI, jer potiče širu primjenu poslovne inteligencije među korisnicima. Za sustave MPI potrebno je provesti edukaciju korisnika i upoznati korisnike s mogućnostima koje pruža MPI što može dovesti do učinkovitijeg korištenja.

Uvođenje sustava MPI iziskuje mnoge izazove kao što su smještanje na malom prostoru (memorije), manji ekran i ograničena interakcija, a izvješća i dashboardi ne smiju sadržavati

previše informacija što bi dovelo do nepreglednosti. Funkcija pretraživanja ili meni zasnovan na izboru trebao bi korisnicima omogućiti da brzo lociraju tražene nadzorne ploče i izvješća. Na umu se mora imati i vrhunska izvedba upita korisnika i kontinuirana dostupnost podataka, jer se radi o vremenski osjetljivim korisnicima MPI.

U situacijama u kojima ne postoji konstantna povezanost na mrežu, korisnici žele podacima pristupiti offline, ali takav način predstavlja izazov zbog sigurnosti podataka.

2.3. Specifičnosti mobilne poslovne inteligencije

Mobilna poslovna inteligencija se razlikuje od tradicionalnih oblika PI. Uređaji su drugačiji (tableti umjesto desktop računala), potrebe su drugačije (podaci se odnose na samo jednog kupca a ne na sve), pažnja kupca se razlikuje (na putu je i vjerojatno nema usmjerenu pažnju).

Prednosti korištenja MPI su ogromne. Prilikom donošenja odluka korisnik se nalazi na licu mjesta (razgovori, sastanci, razgovori s klijentima i partnerima), MPI je prilagođen za gledanje na malim ekranima i grafovi su jednostavniji. MPI je integriran na način da izvješća prikazuje na mobilnim uređajima te omogućuje donošenje odluka u realnom vremenu. Trenutno ne postoji jedinstveni standard za aplikacije MPI i izazov je za proizvođače takvih sustava da prilagode softver za razne korisnike i uređaje.

Neki proizvođači softvera za poslovnu inteligenciju su integrirali trenutni sustav poslovne inteligencije u mobilne uređaje, a neki zahtijevaju poseban server za push na mobilne uređaje. Metode implementacije ovise o različitim proizvođačima. Neki proizvođači koriste push tehnologiju za osiguravanje najnovijih podataka, dok drugi proizvode softver koji korisnici prvo trebaju otvoriti da bi dobili najnovije podatke (*engl. pull*). Bitna stavka MPI je osiguravanje sigurnosti podataka (integritet, raspoloživost i povjerljivost) i mnogi proizvođači softvera uključuju enkripciju i autorizaciju u svojim aplikacijama.

Jedan od problema je implementacija na mobitelima koji imaju male ekrane i ograničenu memoriju. Problem je što sve staviti na veličinu ekrana koja je manja od 21 inča. Umjesto da se pokuša staviti sve što je i na desktop verziji PI, dovoljno je istražiti koje poslovne procese

korisnici obično koriste kroz sustave PI i nakon toga dizajnirati mobilne aplikacije koje imaju vizualno slične nadzorne ploče kao na desktop računalima, ali korisnici odabiru unaprijed što žele pratiti te se prema tome prilagođava i sama aplikacija na mobitelu.

Ne treba inzistirati na unofornosti/jedinstvenosti

Poželjno je prilagoditi nadzorne ploče za različite skupine korisnika na temelju njihovih uloga. Kreiranje nadzornih ploča prema potrebama korisnika pomaže dizajnerima da maksimalno iskoriste uporabu zaslona. Aplikacije MPI će se razlikovati za prodavače, menadžere i operativne timove i ti zahtjevi bi trebali biti unaprijed definirani pogotovo zato jer svi ti različiti zahtjevi ne mogu biti smješteni u istu aplikaciju. Npr., za korisnike koji ne koriste Internet, web bazirana aplikacija bi bila neupotrebljiva ako se ne mogu spojiti na bežičnu mrežu i u takvim slučajevima web aplikacija treba biti bazirana na lokalnom cacheu.

Agilni razvoj

Mobilni korisnici su zahtjevni korisnici a korištenje agilne metode razvoja omogućuje lakšu izmjenu i modifikaciju aplikacije.

Push podataka

Izvjешća prilagođena grupama korisnika se šalju na mobilne uređaje prema unaprijed određenom rasporedu, što je jedan veliki plus kod mobilne poslovne inteligencije.

Aplikacije mobilne poslovne inteligencije nisu samo lijepo sučelje

Dobar dizajn je jedna od najvažnijih stvari na MPI, ali još bitnija stvar je "user-friendly" sučelje. Za managere je bitno da bude osigurana obrada i dostava podataka korisnicima pravovremeno. Važno je imati dobar mobilni Internet i potporu mobilne aplikacije kroz server koji pokreće aplikaciju u pozadini. Veličina infrastrukture ovisi o tome koliko je velika firma i što se želi postići.

Podaci za MPI dolaze iz skladišta ili baze podataka. Podatke može zatražiti sam korisnik kroz upite u realnom vremenu (*engl. real-time queries*) ili kroz push poruke ako dođe do neke promjene podataka.

Kako bismo raspoznali raspon funkcionalnosti aplikacija PI, potrebno je raspoznati i vrste korisnika. Postoje korisnici koji zahtijevaju podatke i oni koji podatke proizvode (poslovni analitičari, statističari itd..)

Nove vrste poslovnih mobilnih aplikacija ujedinjuju tri važna svojstva (From Insight to Action, 2011):

- 1. Poslovna inteligencija**
- 2. Transakcije**
- 3. Multimedija**

To su osnovna svojstva koja će proizvesti najkorisnije mobilne aplikacije poslovne inteligencije od kojih će svaka sadržavati kombinaciju između te tri ključne mogućnosti.

Poslovna inteligencija – analitička funkcionalnost mobilne poslovne inteligencije uključuje grafove, vizualizaciju podataka, pretraživanje podataka, OLAP analizu kao i sortiranje i dublju analizu podataka na bilo kojem mjestu preko mobilnog uređaja. Tipična poslovna inteligencija seli se sa stolnih računala na mobilne uređaje. Mobilnost daje aplikacijama dodatnu interaktivnost što poslovnu inteligenciju čini još korisnijom. Omogućuje menadžerima pregled velike količine informacija preko pametnih telefona ili tableta i potiču na izvršavanje određenih poslovnih aktivnosti bilo gdje i bilo kada bez potrebe za traženjem mjesta za uključivanje laptopa u struju.

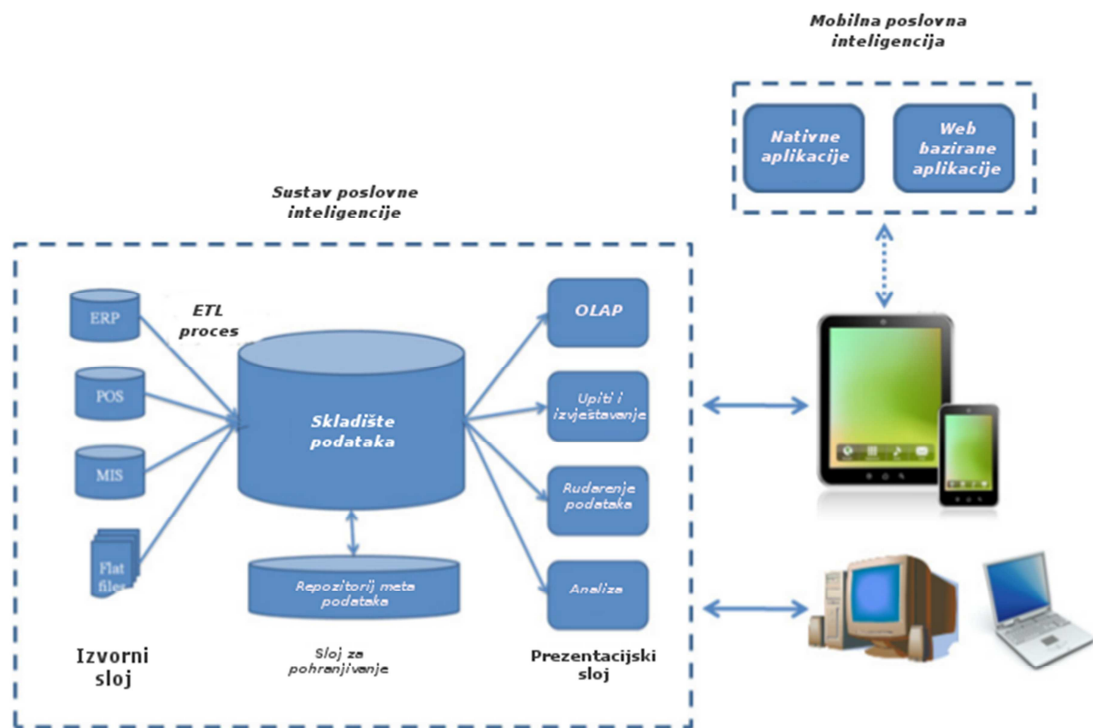
Transakcije – dio mobilne poslovne inteligencije koji omogućuje menadžerima i ostalim donosteljima odluka da direktno prijeđu sa poslovnog uvida na poslovnu akciju, sve preko mobilnog uređaja. Pomoću MPI, transakcije se izvršavaju direktno na osnovu informacija na mobilnom uređaju. Takve transakcijske aplikacije služe pojedincima i organizacijama za trenutno poduzimanje akcija. Zaposlenici mogu unositi podatke, odobravati zahtjeve, vršiti prognoze, dodavati komentare, unositi slike, skenirati SKU4 (*eng. Stock keeping unit*) proizvoda i još mnogo toga bez da se moraju vraćati za stolno računalo. Sve ove akcije odmah se šalju prema transakcijskom sustavu što ubrzava poslovnu aktivnost tako što podaci direktno dolaze do ERP sustava ili baze podataka te se tamo ažuriraju. Prema istraživanju Yankee organizacije 2010. ukupna vrijednost mobilnih transakcija u svijetu bila je oko 160

milijardi dolara, a predviđa se da će 2014. ta vrijednost biti preko 980 milijardi (Yankee Group, 2011).

Multimedija – mobilne aplikacije svoj veliki uspjeh duguju korištenju multimedijских sadržaja. Ovi sadržaji omogućuju kompanijama stvaranje mobilnih aplikacija koje sadrže video isječke, pdf datoteke, knjige, web sadržaje i sl. Tableti i pametni telefoni sadrže pdf čitače, e-mail, web pretraživače, web stranice što dovodi do bogatog sadržaja dostupnog na dlanu korisnika koji se automatski ažurira. Mobilne aplikacije mogle bi postati nova generacija tv kanala. Svaka mobilna aplikacija obogaćena multimedijom može imati veliki utjecaj na današnje poslovanje na dnevnoj razini. Npr. trgovac dok je na terenu može sa svog mobilnog uređaja pogledati neke instrukcijske video uratke ili snimke svjedočenja kupaca koji bi mu pomogli u postizanju prodaje ili kod sastanaka sa klijentima.

2.4. Razvoj sustava mobilne poslovne inteligencije

Iako su prednosti MPI velike, prije same implementacije treba opravdati učinke MPI te MPI uskladiti sa cjelokupnom strategijom poslovne inteligencije. Preporučuje se takozvani *Fit-Viability* (održivi) model za usvajanje mobilne tehnologije u poslovanju i sugerira da organizacije trebaju implementirati MPI samo kada su i FIT i VIABILITY visoki kako bi se osigurao uspjeh. Fit mjeri opseg usklađenja s osnovnim smjericama, kulturom, strukturom i vrijednostima organizacije, a viability se odnosi na organizacijsku, ekonomsku i infrastrukturnu spremnost i izvedivost za provedbu mobilne tehnologije. (Liang, Wei 2004.)



SLIKA 2. 1. Infrastruktura MPI

Izvor: prilagođeno prema Mobile Business Intelligence: Intelligence at the Fingertips, School of Management Studies, University of Hyderabad, Hyderabad

Postoje određeni preduvjeti koje treba poštivati pri odabiru arhitekture MPI:

Mobilna platforma:

Jedna od ključnih odluka je vrsta mobilne platforme. Postoje dvije podvrste: klijentsko-poslužiteljska arhitektura i web bazirana arhitektura. Odluka o mobilnoj platformi utječe na sve daljnje odluke.

Korisničko iskustvo (engl. User experience)

Arhitektura MPI treba korisnicima omogućiti da iskoriste mobilne mogućnosti za uvid u podatke i da se jednostavno njima koriste. Neke važne značajke uključuju individualnu i grupnu personalizaciju, grafove i vizualizaciju podataka.

Sigurnost

Informacije trebaju biti dostupne korisnicima i sigurne od dostupa neovlaštenim osobama, gubitkaka ili vanjskih prijetnji.

Integracija s postojećim sustavom poslovne inteligencije i ostalim korporativnim rješenjima

Mobilna platforma za PI treba biti integrirana s postojećim sustavom PI i drugim softverskim aplikacijama organizacije.

Administracija

Alati trebaju biti dostupni na način da omoguće učinkovito i opsežno upravljanje mobilnom platformom i njezinim funkcijama i značajkama.

Gore navedeni su općeniti zahtjevi koje trebamo očekivati od MPI, ali postoje i specifični elementi koje trebmo uzeti u obzir prilikom implementacije MPI. Elementi poput interakcije s drugim korisnicima i svrdlanje podataka mogu igrati važnu ulogu u poboljšanju procesa donošenja odluka u pokretu. Otkrivanje podataka, pretraživanje sposobnosti sustava za pronalaženje informacija i lociranje podataka su isto tako važni elementi.

Kako započeti proces odabira platforme sustava mobilne poslovne inteligencije?

MPI mora stvarati vrijednost – implementacija rješenja koja se mogu integrirati s postojećim aplikacijama i da pružaju mnoge mogućnosti podrške i pouzdano razvojno okruženje.

Mogućnost implementacije mobilnih rješenja PI bez mijenjanja temeljnih aplikacija – odnosi se na rješenja koja mogu biti učinkovita i operativna s manje napora u smislu implementacije, konfiguracije i administracije.

Mobilna rješenja moraju biti integrirana s postojećim mobilnim aplikacijama – rješenje koje ima potencijal da integrira sa ostalim aktualnim ili planiranim mobilnim aplikacijama

Sustav MPI mora biti neoovisan o uređaju – sustav koji ne ovisi o mobilnom uređaju ili o mobilnom operativnom sustavu.

Sustavi MPI moraju biti temeljeni na ulogama korisnika i korisnički orijentirani – sustav koji pruža korisnicima mogućnost konfiguriranja vlastitog radnog okruženja u skladu s njihovim potrebama

MPI mora unaprijediti i/ili integrirati s organizacijskom strategijom oko sigurnosti podataka – potrebno je osigurati sve aspekte sigurnosti podataka na razini uređaja, prijenosa podataka i mreže.

Podjela aplikacija mobilne poslovne inteligencije (Evelson, 2009):

Prilagođene (customized) aplikacije –izvještaji, grafovi i nadzorne ploče su u formatu prilagođenom za rad na tom uređaju. Sadržaj je prilagođen veličini ekrana i jednostavna je navigacija tim sadržajem. Kompliciranije su za izradu od mobilnih aplikacija prilagođenih web pregledniku , ali ne zahtijevaju dodatan softver.

Serverske aplikacije poslovne inteligencije – zahtijeva softver od dobavljača sustava poslovne inteligencije. Ima slična svojstva kao i prethodna vrsta aplikacija osim što se rad aplikacije vrši na serveru, a nije u rukama programera.

Mobilne aplikacije poslovne inteligencije za klijente – najnaprednija vrsta aplikacija, pruža potpunu interaktivnost sa sadržajem koji se pregledava na uređaju. Nudi i mogućnost pregleda i analize podataka izvan mreže (*engl. offline*).

Postoje 2 načina implementacije sustava mobilne poslovne inteligencije: Nativne aplikacije i web-bazirana rješenja.

2.4.1. Nativne mobilne aplikacije (engl. Native mobile applications)

Nativne mobilne aplikacije koriste temeljne programske jezike (npr. Java, programski jezik C itd.), API-je (*engl. application programming interface*²) i značajke koje su direktno povezane sa određenim operativnim sustavom. Svaka aplikacija zahtijeva posebno programiranje za svaki operativni sustav. Pošto je svaka aplikacija dizajnirana za pojedini operativni sustav, ima potencijal potpunog iskorištenja svojih mogućnosti i kreiranja bogatijih grafika. Osiguran offline pristup podacima čini aplikaciju portabilnom posebno za nadzorne ploče (*engl.dashboards*) koje sadrže puno podataka.

Prednosti su: performanse, poboljšano korisničko iskustvo i offline pristup. Baza podataka je skinuta na mobitel i pohranjena. Vrlo responzivna i s velikim performansama. Zbog spremanja podataka na uređaj, aplikacija može raditi i u offline modu.

² API – aplikacijsko programsko sučelje je skup protokola i rutina koje računalni sustav,ili aplikacija osigurava drugim aplikacijama za obavljanje zahtjeva i usluga tim aplikacijama.

2.4.2. Web bazirana rješenja (engl. Browser based applications)

Mobilne aplikacije kojima se pristupa preko web preglednika mogu se koristiti na gotovo bilo kojem mobilnom uređaju koji podržava web pretraživanje i isključivo HTML aplikacije. Web bazirane aplikacije MPI se programiraju u HTML5 jeziku. HTML5 je širok prepoznat standard koji je podržan od različitih proizvođača mobitela, odnosno mobilnih sustava. Prednosti su što puno programera poznaje html5 i aplikacija se može učitavati na raznim mobilnim uređajima. Nedostatak je što je teško upravljanje za korisnike, ima ograničenja na složene procese i nema osigurano offline spremanje podataka.

Prednosti su: portabilnost, sigurnost i dosljednost podataka. Programeri ne trebaju razmišljati o programiranju za različite mobilne uređaje, nego napišu jedinstveni kod za web browser. Svi podaci se nalaze na serveru i nisu spremljeni na mobilne uređaje. Svi korisnici pristupaj istom serveru koji omogućuje dosljednost podataka. Jednostavnije je osigurati sigurnost podataka kada se podaci i lozinke nalaze na jednom serveru. Ako netko ukrade uređaj, ne može se pristupiti osjetljivim podacima tvrtke.

Nedostatak ovih aplikacija je njihova statičnost, nepreglednost, loša navigacija, a omogućeno je isključivo pregledavanje podataka bez mogućnosti interakcije.

Postoje i hibridna rješenja MPI:

2.4.3. Nativno hibridno rješenje

Ponudajući aplikacija MPI ugradili su u aplikacije portabilnost, sigurnost i konzistentnost podataka. Neki su razvili aplikacije koje odgovaraju bilo kojem sustavu na uređaju. Kako bi se osigurala konzistentnost podataka, neki proizvođači su omogućili da se prilikom pokretanja aplikacije downloadiraju svježiji podaci sa servera ili automatski ili na zahtjev korisnika. Sa sigurnosne strane korisnicima su dane administrativne ovlasti da obrišu podatke sa uređaja u slučaju gubitka (nakon krađe se spajaju na server i odlučuju s kojeg uređaja obrisati podatke). Također se i prilikom ulaska u aplikaciju u offline mode-u traži lozinka.

2.4.4. Hibridno web bazirano rješenje

Hibridna aplikacija donosi prednosti iz obje vrste programiranja aplikacija MPI. U takvoj vrsti programiranja aplikacije optimiziraju se Java i CSS kako bi se održao bogat dizajn s interaktivnim sadržajem i lijepim izgledom. Pisanje koda u HTML-u omogućuje i primjenu na različitim mobilnim uređajima tako da se osigura rad na bilo kojoj platformi. S druge strane, to ne treba žrtvovati prednosti koje nude nativne mobilne aplikacije. Omotavanjem HTML-a, JavaScripta i CSS-a u nativno programiranu aplikaciju dobivamo rješenje MPI pomoću kojeg možemo pristupiti podacima i u offline mode-u, puno brže reagiranje, visoku kvalitetu grafike i animacija.

Rješenja temeljena na web pregledniku poboljšavaju performanse i iskoristivost aplikacija. Web bazirana rješenja koriste neke nativne karakteristike kao što su pokreti ruku (*engl. hand gestures*), unos podataka i kretanje između portret i landscape izgleda.

Mobilna PI	Prednosti	Nedostaci
Web bazirane aplikacije	<ul style="list-style-type: none">▪ Jednostavniji razvoj aplikacije▪ Kompatibilne sa svim web preglednicima	<ul style="list-style-type: none">▪ Ne-funkcionalnost na mobitelima▪ Isključivo online pristup▪ Manja funkcionalnost
Nativne aplikacije	<p>Veća funkcionalnost Mobilna optimizacija Offline pristup</p>	<p>Nije kompatibilna sa svim mobilnim uređajima/sustavima</p>

SLIKA 2. 2. Nativna vs. Web bazirana rješenja

Izvor: <http://v1.aberdeen.com/launch/report/perspective/8646-AI-mobile-applications-browser.asp?lan=US>

Osim tradicionalnih rješenja, sve popularnija postaju razna Cloud rješenja pa tako i za sustave poslovne inteligencije.

2.4.5. Računalstvo u oblaku i mobilna poslovna inteligencija

Računalstvo u oblaku je model obrade podataka koji omogućuje sveprisutan i jednostavan pristup skupu djeljivih računalnih resursa poput računalnih mreža, poslužiteljskih računala, medija za pohranu podataka, aplikacija i usluga, koje je moguće konfigurirati i stavljati na raspolaganje korisnicima uz njihov minimalan osobni angažman ili uz najmanju moguću interakciju s pružateljem tih resursa. (Panian, 2013)

Krajnji korisnici mogu koristiti masovne računalne resurse bez posebnih ograničenja i do resursa mogu doći brzo i jednostavno.

Postoji nekoliko karakteristika zbog kojih se neka usluga može smatrati računalstvom u oblaku, a to su: usluge korisnik može koristiti sam po zahtjevu, široke mogućnosti pristupanja uslugama, dijeljenje resursa, elastičnost, mjerljivost usluga.

Još jedan pristup razvoja mobilne poslovne inteligencije može biti i računalstvo u oblaku.

Postoje tri modela računalstva u oblaku:

a) Softver kao usluga - (engl. *Software as a Service (SaaS)*)

Korisnici se služe sa sotverskim aplikacijama, ali ne kontroliraju hardver ili mrežnu infrastrukturu na kojoj se ta aplikacija izvodi. Korištenje softvera kao usluge je jednostavno. To su računalne usluge poput uredskih ili backup alata koje se korisniku isporučuju putem Interneta, a on ih plaća prema potrošnji (uobičajenije) ili pretplati. Korisnik ne mora imati plaćenu licencu da bi koristio software.

Karakteristike modela softvera kao usluge su: pristup komercijalnom softveru je omogućen putem weba, softverom se upravlja putem neke centralne lokacije, softver se isporučuje po modelu "jedan prema više", korisnici ne moraju brinuti o nadogradnjama i prilagodbama softvera, a aplikacijska programska sučelja omogućuju integraciju različitih segmenata softvera.

b) Platforma kao usluga (engl. *Platform as a Service (Paas)*)

Korisnik koristi okruženje udomljavanja (engl. *hosting*) za svoje aplikacije. Kontrolira aplikacije koje koristi i jedan dio okruženje udomljavanja, ali nema kontrolu nad operacijskim sustavom ni mrežnom infrastrukturuom na kojoj se aplikacije izvode.

Svojstva modela platforme kao usluge su: objedinjavanje usluga razvoja, testiranja, primjene, udomljavanja i održavanja aplikacija u jednom integriranom okruženju, alati za kreiranje korisničkog sučelja zasnovanog na webu pomažu pri stvaranju, modificiranju, testiranju i primjeni različitih scenarija izgleda i korisničkog sučelja, višeporabna arhitektura omogućuje većem broju korisnika korištenje iste razvojne aplikacije, ugrađena proširivost odnosno skalabilnost korištenog softvera omogućuje uravnoteženje opterećenja hardvera i obnavljanje svih aktivnosti i nakon pada sustava, omogućena je integracija s web uslugama i bazama podataka uz primjenu općih standarda, platforma kao usluga pruža punu podršku suradnji unutar i između razvojnih timova i uključeni su i alati za upravljanje pretplatom i obračun i naplatu usluga.

c) Infrastruktura kao usluga (*engl. Infrastructure as a Service (IaaS)*)

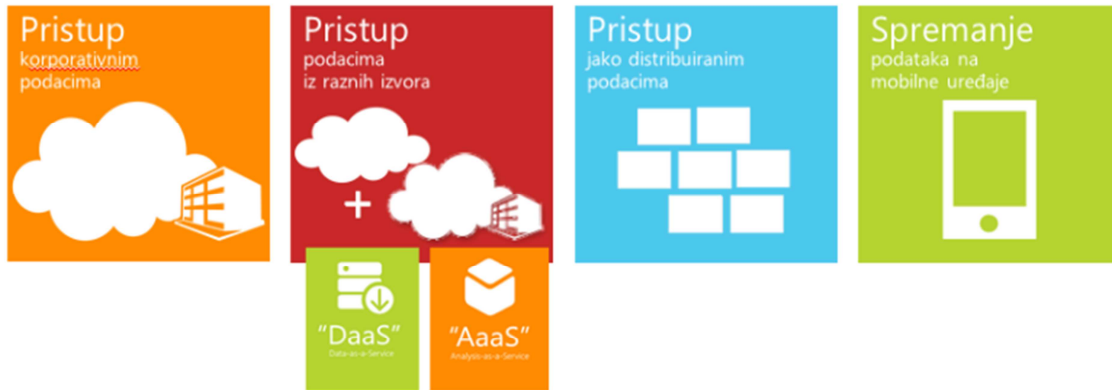
Infrastruktura kao usluga je način isporuke infrastrukture računalstva u oblaku – poslužiteljskih računala, prostora za pohranu podataka, mreža i operacijskih sustava – kao usluge po zahtjevu. Umjesto da kupuju računala, softver, uređaje za pohranu podataka, prostor za smještaj hardvera i mrežnu opremu, klijenti kupuju te resurse kao potpuno eksternaliziranu uslugu shodno njihovim aktualnim potrebama i zahtjevima. (Panian, 2013)

Virtualizirana okruženja koja se isporučuju krajnjem korisniku kao usluga, a uključuju servere, mrežnu opremu te aplikacije. Korisnik kontrolira bazične računalne resurse poput procesne moći, prostora za pohranu podataka, mrežnih komponenata ili softvera. Također može kontrolirati i operacijski sustav, uređaje za pohranu podataka i primijenjene aplikacije, ali infrastruktura samog oblaka ostaje izvan korisnikove kontrole.

Karakteristike navedenog modela su: svi se resursi isporučuju kao usluge, omogućeno je dinamičko proširenje usluge, troškovi korištenja su varijabilni jer se primjenjuje model plaćanja prema uporabi i model omogućuje da isti hardver istovremeno koristi veći broj konzumenata, odnosno korisnika.

Mobilni uređaji općenito imaju manjak memorije i računalne snage u usporedbi sa osobnim računalima i taj nedostatak automatski ograničava mogućnosti MPI. Mobilno računalstvo se odnosi na upotrebu "oblaka" za pohranu i korištenje podataka i može pomoći u smanjivanju ograničenja mobilnih uređaja. Treba imati na umu da povećano korištenje mobilnih aplikacija u cloud rješenjima može dovesti do smanjenja trajanja baterija i treba postići kompromis između performansi i baterije. Cloud računalstvo dolazi sa vlastitim skupovima izazova i

problema koji uključuju visok računalni bandwidth i konstantni pristup Internetu, sigurnost i nedostatak industrijskih standarda.



Slika 2. 3. Scenariji korištenja MPI u oblaku

Izvor: https://bib.irb.hr/datoteka/583887.CASE-Mobilna_poslovna_inteligencija_i_racunarstvo_u_oblaku-ASTIPIC_TBRONZIN-1_3.pdf

Pristup korporativnim podacima je usluga koja omogućuje mobilni pristup internoj mreži korisnikove tvrtke.

Pristup podacima iz različitih izvora je vrlo važan za izradu strateških poslovnih procjena u vrlo kratkom vremenskom razdoblju. Multi-cloud rješenje može pružiti podatke iz nekoliko različitih izvora, ali i određeni uvid u te podatke. To može imati obilježja kooperativne PI, jer tvrtke trebaju biti spremne podijeliti neke važne informacije sa ostalim tvrtkama koje sudjeluju kako bi došlo do usporedbe različitih pokazatelja uspješnosti.

Pristup jako distribuiranim podacima se odnosi na podatke koji nisu prvenstveno poslovne prirode i mogu biti podaci unutar različitih društvenih mreža. Takav pristup se naziva i socijalna inteligencija.

Slučaj spremanja podataka je različit od tri navedena prethodna slučaja, jer umjesto da povlači podatke iz oblaka, prenosi prikupljene podatke s mobilnog uređaja u oblak.

Rješenja mobilne poslovne inteligencije u oblaku su temljena na softveru kao usluzi (SaaS). Takva rješenja su manje zahtjevnja za implementaciju i manje su troškovno zahtjevnja.

Kao prednosti mobilne poslovne inteligencije u oblaku navode se: brža stopa povrata ulaganja, niži troškovi implementacije, niži troškovi održavanja, povećana suradnja, skalabilnost – laka ugradnja od odjela pa sve do razine cijele organizacije, agilnost – laka prilagodba na promjene poslovnih zahtjeva, lako dijeljenje podataka i izvještaja.

Svaki od navedenih rješenja ima svoje prednosti i nedostatke. Važna prednost nativnih aplikacija je offline pristup. Dok nativne aplikacije mogu pružiti bolje značajke i performanse, one se moraju razvijati za svaki pojedini uređaj, odnosno mobilnu platformu i to može biti dosta zahtjevno. Ako organizacija zahtjeva od zaposlenika da imaju svoje vlastite mobilne uređaje, tada je problem još veći. Jedinstveni sigurnosni elementi na različitim uređajima moraju biti postavljeni adekvatno.

MPI ostvarena preko web preglednika, pruža rješenja neovisna o platformi na mobilnom uređaju i o samom uređaju omogućavajući politiku razvij jednom, a implementiraj bilo gdje. Isto tako, web bazirana rješenja oslobađaju organizacije od razvijanja aplikacija za svaki mobilni uređaj posebno, a sigurnost se lakše provodi. Nedostatak je što nedostaju industrijski standardi za tako kreirane aplikacije.

Hibridni pristup kombinira nativna i web bazirana rješenja u kojemu se nativno rješenje pokreće u web pregledniku. Hibridna tehnologija još uvijek nije široko rasprostranjena na mobilnim sustavima i uređajima.

2.5. Sigurnost podataka na mobilnoj poslovnoj inteligenciji

Prema istraživanju TDWI 2011. godine koje je provedeno na svjetskoj razini, najveća prepreka uvođenju MPI je strah od gubitka podataka, odnosno zabrinutost za njihovu sigurnost.

Mobilne aplikacije trebaju biti sigurne na tri razine: na razini uređaja, prijenosa podataka i kod autorizacije, autentifikacije te na mrežnoj razini.

2.5.1. Sigurnost na razini uređaja

Preporuka za sigurnost na mobilnim uređajima je da se podaci ne spremaju isključivo na mobilni uređaj, jer ako dođe do otuđenja uređaja, pristup podacima je nemoguć. Podatke bi trebalo pohraniti na server i njima se u svakom trenutku može pristupiti preko mreže. Dobavljači mobilne poslovne inteligencije su svjesni koliko je sigurnost podataka bitna stavka mobilnih aplikacija te u svoje softvere ugrađuju enkripcije mobilnog diska, email enkripciju kao i daljinsko upravljanje podacima, odnosno mogućnost brisanja podataka, ako postoji nemogućnost pristupa podacima s mobilnog uređaja.

2.5.2. Sigurnost prijenosa podataka

Sigurnosne mjere koje se odnose na prijenos podataka su: zaštita podataka od neovlaštenih prisluškivanja, zaštita od analize i oponašanja prometa podataka. Siguran prijenos podataka treba imati identitet pošiljatelja, a primatelj podataka treba koristiti kriptografski ključ za pregled podataka i DES (*engl. Data Encryption Standard*) i AES (*engl. Advanced Encryption Standard*) ključeve protiv neovlaštenog mijenjanja podataka.

2.5.3. Autorizacija, autentifikacija i mrežna sigurnost

Autorizacija se odnosi na specificiranje prava pristupa određenim podacima i određenim grupama korisnika, dok je autentifikacija potvrda korisnika.

Mrežna sigurnost su pravila koja su postavljena od strane mrežnog administratora s ciljem sprječavanja i praćenja neovlaštenog pristupa, zloupotrebe ili modifikacije podataka. Mobilne aplikacije su izazov za postavljanje sigurnosnih postavki iz razloga što se mobilnim uređajima korisnici služe i izvan organizacije, odnosno posla. Pravilna autentifikacija, autorizacija, centralizirani pristup i šifrirani mehanizmi prijenosa podataka, predstavljaju svojevršno rješenje za sigurnost aplikacija mobilne poslovne inteligencije.

2.6. Primjena mobilne poslovne inteligencije

Prema istraživanju TDWI, 2011., na uzorku od 541 tvrtke poslovni korisnici su vrlo uzbuđeni zbog načina na koji bi mobilna poslovna inteligencija promijenila menadžment performansi,

planiranje i donošenje svakodnevnih odluka. Najveća prepreka uvođenju MPI je strah od gubitka podataka, odnosno zabrinutost za njihovu sigurnost.

Istraživanje je pokazalo da je najpoznatija platforma za MPI Apple iOS sa 2/3 korisnika obuhvaćenih istraživanjem, dok je na drugom mjestu Android platforma.

Tvrtke će u većini slučajeva koristiti obje vrste MPI – i native i web bazirana rješenja, a neke od njih će uzeti i hibridna rješenja.

61% tvrtki očekuje unutar 12 mjeseci (do kraja 2012 godine) da će korisnici više vremena provoditi na mobilnim uređajima u pristupanju PI i analitičkim aplikacijama u sklopu PI, a 24% navode da će potrošiti istu količinu vremena kao i do sada.

53% ispitanika je odgovorilo da manje od 10% korisnika koji već koriste neki oblik PI, koristi i mobilnu poslovnu inteligenciju, a njih 16% je navelo da se MPI koristi između 10 i 25% . Iako se radi o relativno malom postotku, istraživanje pokazuje da ta brojka raste iz godine u godinu.

Očekivanja koja poslovni korisnici imaju od uvođenja MPI su: 65% očekuje povećanje prodaje proizvoda i usluga, 60% očekuje povećanje efikasnosti upravljanja poslovnim procesima, a 50% očekuje bržu implementaciju poslovne inteligencije, analitičkih aplikacija i servisa.

Tvrtke su prepoznale važnost uvođenja MPI i 43% ispitanika sustav MPI navodi kao važan, a njih 28% kao izrazito važan.

83% ispitanika navodi da su najvažniji dio poslovne inteligencije, kako na desktopu, tako i na mobilnim uređajima, nadzorne ploče. Nadzorne ploče prikazuju izvješća, analize, šalju upozorenja i vizualiziraju podatke, a kao najveći problem iznose da je ne moguće pristupiti nadzornim pločama s mobilnih uređaja ili da se oni drugačije prikazuju nego na desktop PI.

Prema istraživanju Ventana Research najpoznatiji proizvođač Mobilne poslovne inteligencije je MicroStrategy sa najvećim tržišnim udjelom.

3. ISTRAŽIVANJE POSLOVNE I MOBILNE POSLOVNE INTELIGENCIJE U HRVATSKOJ


U razdoblju od 15. lipnja do 31. kolovoza, provedeno je istraživanje o poslovnoj i mobilnoj poslovnoj inteligenciji u malim i srednjim poduzećima u Republici Hrvatskoj. Poziv za ispunjavanje online ankete je poslan na ukupno 1200 mail adresa iz 1100 malih i srednjih poduzeća u Republici Hrvatskoj, a upitnik je u potpunosti kompletiralo 83 tvrtke, što je odaziv od 7,5%.

Anketa se sastojala od ukupno 30 pitanja i podijeljena je u 3 dijela. Prvi dio se odnosi na podatke o ispitaniku (naziv tvrtke, grad, županija, industrija kojoj tvrtka pripada itd.), drugi dio je općenito poznavanje poslovne inteligencije, a treći dio ankete se odnosi na mobilnu poslovnu inteligenciju.

Anketa je izrađena na online aplikaciji limesurvey.srce.hr, a podaci su obrađeni pomoću iste te aplikacije te Excel programa.

Cilj istraživanja je bio saznati koliko je malih i srednjih poduzeća u RH upoznato s pojmom poslovne inteligencije općenito, da li navedene tvrtke imaju odjel poslovne inteligencije, koliko važnim smatraju strategiju upravljanja podacima, da li su upoznati s pojmom mobilne poslovne inteligencije te da li koriste neki oblik.


Istraživanje je provedeno na uzorku 83 poduzeća iz cijele Hrvatske, a postoci sudjelovanja po županijama su sljedeći: Zagrebačka županija i grad Zagreb 48,19%, Istarska županija, 10,84%, Primorsko-goranska i splitsko-dalmatinska županija 7,23%, varaždinska, bjelovarsko-bilogorska i osječko-baranjska županija 3,61%, sisačko-moslavačka, karlovačka i zadarska županija 2,41%, krapinsko-zagorska, kopriivničko-križevačka, požeško-slavonska, brodsko-posavska, vukovarsko-srijemska, dubrovačko-neretvanska i međimurska 1,2% dok iz županija ličko-senjske, virovitičko-podravske i šibensko-kninske, u istraživanju nije sudjelovala nijedna tvrtka.



SLIKA 3. 1. Postotak sudjelovanja u istraživanju po županijama

Izvor: Izrada autora


Prema Sikavica, Novak (1999.) postoje sljedeće poslovne funkcije u poduzeću: direktor poduzeća, istraživanje i razvoj, proizvodnja, marketing, financije i računovodstvo i ostali stručni poslovi. Kao poslovnu funkciju, u istraživanje je još dodana funkcija IT stručnjaka. Najviše sudionika koji su odgovarali na upitnik, bili su direktori (44,57%) dok je druga po redu funkcija IT stručnjaci (19,27%). Najveći postotak direktora i IT stručnjaka upućuje na najbolje razumijevanje problematike istraživanja. Treća poslovna funkcija su ostali stručni poslovi (18,07%), zatim marketing i financije i računovodstvo (svaka sa 8,43%) i na kraju istraživanje i razvoj (1,2%) dok iz poslovne funkcije proizvodnje nema niti jednog sudionika.



SLIKA 3. 2. Postotak sudionika prema poslovnim funkcijama

Izvor: Izrada autora

Što se uporabe pojma za prikupljanje, analizu i obradu podataka tiče, stvorena je lista najpreferiranih pojmova koji tvrtke koriste, a to su: istraživanje tržišta (62,25%), business intelligence (37,35%), poslovna inteligencija (24,10%), monitoring tržišta (19,28%), upravljanje znanjem (19,28%), competitive intelligence (6,02%), market intelligence (6,02%), niti jedan pojam nije znalo 4,82%, a razgovor u četiri oka je odgovorilo 1,2% (1 tvrtka).




SLIKA 3. 3. Pojmovi za prikupljanje, analizu i obradu podataka

Izvor: Izrada autora

U Hrvatskoj postoje razni pojmovi za poslovnu inteligenciju i svaka od tvrtki koristi pojam koji smatra najprikladnijim za prikupljanje i analizu poslovnih podataka u svrhu poslovnog odlučivanja.

Istraživanjem je ispitano koje podatke tvrtke skupljaju u svrhu donošenja odluka. Sudionici su mogli odabrati više odgovora na jedno pitanje i slijedom toga, dobiveni su sljedeći rezultati: o kupcima (84,34%), o konkurentima (67,47%), o potencijalnim poslovnim prilikama i mogućnostima (65,06%), o potencijalnim kupcima (62,65%), o dobavljačima (62,65%), o novim proizvodima, uslugama i njihovim cijenama (55,42%), o okruženju poslovanja tvrtke - pravna, gospodarska i politička situacija (51,81%) i ne znam (1,2%).




SLIKA 3. 4. Podaci koje tvrtke prikupljaju

Izvor: Izrada autora

Nadalje se postavlja pitanje da li tvrtke imaju zaseban odjel poslovne inteligencije (slika 3.4.) i odgovori su bili sljedeći: zaseban odjel ima 1,2% tvrtki, 72,29% tvrtki nema zaseban odjel, ali provodi neke aktivnosti poslovne inteligencije, 25,30% tvrtki ne provodi aktivnosti poslovne inteligencije, a 1,2% tvrtki ne zna odgovor.

Iako jako mali broj malih i srednjih poduzeća imaju zaseban odjel, ohrabrujuća je činjenica da više od polovine tvrtki koje su sudjelovale u istraživanju (72,29%) provodi aktivnosti poslovne inteligencije, bez obzira na nepostojanje posebnog odjela.


Najviše tvrtki koje provode aktivnosti poslovne inteligencije, ali nema zaseban odjel je iz djelatnosti trgovine (21,88%), dok je na drugom mjestu industrijska grana informacije i komunikacije (20,83%).



SLIKA 3. 5. Primjena poslovne inteligencije u tvrtkama

Izvor: Izrada autora

U prethodnom pitanju je pokazano koliko se tvrtki bavi aktivnostima poslovne inteligencije te je preispitana i važnost korištenja poslovne inteligencije za uspješnost poslovanja tvrtke. Najveći postotak tvrtki (50,60%) smatra djelomično važno korištenje poslovne inteligencije, 38,55% smatra jako važno, 6,02% smatra korištenje poslovne inteligencije nevažnim, 2,41% smatra djelomično nevažnim, a isto toliko tvrtki nije znalo važnost korištenja poslovne inteligencije za uspješnost poslovanja tvrtke.




SLIKA 3. 6. Važnost korištenja poslovne inteligencije za uspješnost poslovanja tvrtke

Izvor: Izrada autora

Nakon što je pokazano da više od polovice tvrtki koje su sudjelovale u istraživanju koristi poslovnu inteligenciju i smatra je bitnom za uspješnost poduzeća, pitanje koje se postavlja je koliko je i uspješno to upravljanje podacima u pogledu potpore poslovnim ciljevima, jer nije bitno samo upravljanje podacima, nego koliko ono podupire ciljeve poduzeća.


Odgovori su sljedeći: djelomično uspješno (54,22%), uspješno (34,94%), djelomično neuspješno (6,02%), ne znam (4,82%), a neuspješno nije odgovorila niti jedna tvrtka.



SLIKA 3. 7. Uspješnost upravljanja podacima u pogledu potpore poslovnim ciljevima poduzeća

Izvor: Izrada autora

Nakon što je pokazano da organizacije u velikom postotku smatraju da je upravljanje podacima djelomično uspješno i uspješno, postavljeno je pitanje da li postoji i organizacijska strategija za upravljanje podacima. Dobiveni su sljedeći odgovori: proširenje postojećeg sustava da bi bio pogodan za upravljanje podacima (50,60%), nemamo strategiju, ali trebamo je (28,92%), implementacija novog sustava za upravljanje podacima (16,87%), nemamo strategiju i ne treba nam (8,43%), ne znam (3,61%) i ostalo (1,2%).




SLIKA 3. 8. organizacijska strategija za upravljanje podacima

Izvor: izrada autora

Zatim dolazimo do dijela istraživanja, koji se direktno tiče teme diplomskog rada, a to je dio o mobilnoj poslovnoj inteligenciji.


Sa pojmom mobilne poslovne inteligencije je upoznato 56,63% tvrtki dok sa istim nije upoznato 37,35%.



SLIKA 3. 9. Upoznatost s pojmom mobilne poslovne inteligencije

Izvor: Izrada autora


Iako je većina tvrtki upoznata s pojmom mobilne poslovne inteligencije, postotak korištenja je mnogo manji. 27,71% koristi MPI, 61,45% tvrtki ne koristi MPI, a 10,84% se izjasnilo da ne zna.



SLIKA 3. 10. Postotak korištenja mobilne poslovne inteligencije u malim i srednjim poduzećima u Hrvatskoj

Izvor: izrada autora


Oko promjena koje će nastupiti uvođenjem MPI, tvrtke su se izrazile na sljedeći način:



SLIKA 3. 11. koje promjene korisnici očekuju uvođenjem sustava mobilne poslovne inteligencije

Izvor: Izrada autora

Glede aplikacija kojima će korisnici mobilne poslovne inteligencije pristupati su prikazani na donjoj slici:




SLIKA 3. 12. Aplikacije kojima će korisnici najviše pristupati uvođenjem MPI

Izvor: Izrada autora

Organizacije očekuju mnoge prednosti nakon implementacije sustava mobilne poslovne inteligencije, a najvažnije su: brži pristup informacijama za menadžere (49,4%), pristup podacima u realnom vremenu za različite uloge korisnika (43,37%), lakši samoposlužni pristup podacima (37,35%), češće ažurirani podaci za sve korisnike (34,94%) dok su ostali odgovori prikazani u donjem grafu.


Iz odgovora je vidljivo da je tvrtkama najvažniji brz pristup svježim ažuriranim podacima.



SLIKA 3. 13. prednosti koje korisnici očekuju implementacijom sustava MPI

Izvor: Izrada autora

Nakon prethodnih pitanja, nameće se pitanje da li je tvrtka spremna za implemntaciju MPI. 24,1% tvrtki nije spremno, a spremno je 22,89% tvrtki. 44,58% sudionika nije dalo nikakav odgovor.




SLIKA 3. 14. Spremnost tvrtki na implementaciju MPI

Izvor: Izrada autora

Više je tvrtki koje nisu spremne na implementaciju mobilne poslovne inteligencije, iako većina sudionika nije dala ni jedan odgovor pa je pretpostavka da ni te tvrtke nisu spremne na implementaciju MPI. Slijedom toga, nameće se pitanje prepreka uvođenju sustava MPI.


Sudionici su dali sljedeće odgovore: nedovoljan budžet (34,94%), zatim nedovoljno znanje o mobilnim sustavima (24,10%), ne postojanje potrebe za MPI u poduzeću (16,87%), strah od gubitka podataka (15,66%), u 2,41% slučajeva nije prepoznata važnost MPI i ne postoji dovoljan interes, a 6,02% sudionika nije znalo odgovor.



SLIKA 3. 15. Spremnost tvrtki na implementaciju MPI

Izvor: Izrada autora


Za tvrtke koje su uvele Mobilnu poslovnu inteligenciju, pitanje je bilo koja je motivacija prethodila uvođenju, a odgovori su: povećanje produktivnosti 40,96%, brži pristup podacima (37,35%), povećanje zadovoljstva kupaca/korisnika (27,71%), veća suradnja između zaposlenika (26,51%), 6,02% je odgovorilo da ne koristi mobilnu poslovnu inteligenciju.



SLIKA 3. 16. Motivacija koja je prethodila uvođenju MPI u poduzeće

Izvor: Izrada autora

Aplikacije koje se najviše koriste na mobilnim uređajima su navedene na donjoj slici:




SLIKA 3. 17. Najčešće korištene aplikacije mobilne poslovne inteligencije

Izvor: izrada autora

Iz dobivenih podataka vidljivo je da tvrtke najviše koriste email komunikaciju, internet bankarstvo i osobni organizator, dok se poslovna inteligencija na mobilnim uređajima koristi u manjem postotku, svega 10,84% što je puno manje ako taj postotak usporedimo sa email-om npr.

Najčešće korišteni uređaji/operativni sustavi za MPI su:




SLIKA 3. 18. Najčešće korišteni mobilni uređaji/platforme

Izvor: izrada autora

Najvažnije mogućnosti za korisnika mobilne poslovne inteligencije su: prikaz podataka u realnom vremenu (42,17%), mogućnost gledanja izvještaja i grafova (36,14%), multi-touch sučelje (28,92%), a ostale vrijednosti su prikazane grafom.


Korisnici su prepoznali važnost donošenja pravovremenih poslovnih odluka i najbitniji im je prikaz podataka u realnom vremenu, što je i glavna mogućnost mobilne poslovne inteligencije.



SLIKA 3. 19. Najvažnije mogućnosti za korisnike MPI

Izvor: izrada autora


Korisnici mobilne poslovne inteligencije su većinom viši menadžment (48,19%) što je logično obzirom da viši menadžment donosi odluke u poduzeću. Nadalje, IT stručnjaci i programeri (27,71%), niži menadžment i marketinški stručnjaci (svaki po 18,07%), a ostali korisnici se nalaze na slici 3.20.



SLIKA 3. 20. Korisnici MPI u poduzeću

Izvor: izrada autora

Postotak zaposlenika će koristiti mobilnu poslovnu inteligenciju u periodu od 12 mjeseci:



SLIKA 3. 21. Postotak korisnika MPI u narednih 12 mjeseci


Izvor: Izrada autora

Najviše ispitanika (14%) smatra da će u narednih 12 mjeseci, između 11 i 20% korisnika početi koristiti mobilnu poslovnu inteligenciju. 10% smatra da će taj postotak unutar 12 mjeseci biti između 21 i 40%, a ostalih 10% smatra da će postotak zaposlenika koji će unutar 12 mjeseci početi koristiti mobilnu poslovnu inteligenciju biti manji od 10%.

Najveći postotak ispitanika nije znao odgovor (45%) što govori da nemaju jasnu viziju o početku korištenja mobilne poslovne inteligencije u poduzeću.

Situacija je slična i po pitanju zamjene tradicionalne poslovne inteligencije (desktop PI) mobilnom poslovnom inteligencijom. 36,14% korisnika smatra da MPI neće zamijeniti tradicionalni oblik poslovne inteligencije kroz 24 mjeseca, 8,43% smatra da hoće, dok 14,46% ne zna odgovor.

Prema odgovorima iz prethodna dva pitanja je vidljivo da firme neće zamijeniti tradicionalnu poslovnu inteligenciju mobilnom u naredna 24 mjeseca, niti će znatno porasti broj korisnika mobilne poslovne inteligencije u narednih 12 mjeseci.




SLIKA 3. 22. Hoće li tradicionalni oblik PI biti zamijenjen mobilnom poslovnom inteligencijom unutar 24 mjeseca

Izvor: Izrada autora

Podaci mobilne poslovne inteligencije će biti pohranjeni na server (32,53%) što govori da su korisnici svjesni sigurnosnih stavki i prednosti pohranjivanja na serveru, 13,25% i na server i na mobilni uređaj, a 8,43% ispitanika ne zna.


Najveći broj ispitanika (44,58%) nije dalo nikakav odgovor, što govori o neupućenosti u problematiku pohranjivanja podataka MPI.



SLIKA 3. 23. Pohranjivanje podataka MPI

Izvor: Izrada autora

Najčešći dobavljači koje koriste mala i srednja poduzeća u RH su:




SLIKA 3. 24. Dobavljači MPI u Hrvatskoj

Izvor: Izrada autora

Pod ostalo su korisnici naveli svoja rješenja, Bisnode, Microsoft, Tomsoft , Pantheon, Sage. Zanimljiv podatak je da iako je MicroStrategy najveći dobavljač na području poslovne inteligencije, hrvatska poduzeća ga ne koriste.

One tvrtke koje već imaju implementiranu mobilnu poslovnu inteligenciju, ona donosi višestruke prednosti, a to su:




SLIKA 3. 25. Prednosti koje poduzeću donosi korištenje MPI

Izvor: Izrada autora

Vidljivo je da su prednosti koje donosi korištenje mobilne poslovne inteligencije višestruke, a najveća prednost korisnicima je veća učinkovitost i koordinacija poslovnih procesa (44,58%), zatim poboljšana prodaja, usluge i podrška korisnicima (33,73%) i povećana suradnja između zaposlenika (25,3%).

Aplikacije koje korisnici trenutno imaju implementirano ili planiraju implementirati, nativno na mobilnim uređajima ili putem Web sučelja su:



SLIKA 3. 26. Koje aplikacije MPI tvrtke planiraju uvesti

Izvor: izrada autora

Iako je email najviše korištena opcija na mobilnim uređajima, korisnici je planiraju implementirati nativno na mobilnim uređajima ili putem web sučelja.

Povezujući odgovore, autora je zanimalo iz koje županije je najveći postotak tvrtki upoznato s pojmom Mobilne poslovne inteligencije, a odgovor je iz Zagrebačke županije (i grada Zagreba). Postotak iznosi 27,71%. Sljedeće dvije županije u kojima najviše poduzeća zna za pojam Mobilne poslovne inteligencije su: splitsko-dalmatinska i primorsko-goranska, svaka sa 4,82%.

Najviše tvrtki iz djelatnosti trgovine je upoznato s pojmom Mobilne poslovne inteligencije (15,66%), a druga po redu djelatnost su informacije i komunikacije (14,45%). Te djelatnosti su uslužne i dominiraju danas.

Upoznatost s pojmom nije jednako kao i korištenje Mobilne poslovne inteligencije pa se postavlja pitanje da li tvrtke koriste neki oblik mobilne poslovne inteligencije. Najveći postotak tvrtki koje koriste mobilnu poslovnu inteligenciju, dolazi iz Zagrebačke županije (i grada Zagreba) sa 12,05%, a sljedeća županija nakon Zagrebačke je splitsko-dalmatinska i

primorsko-goranska, svaka sa 3,61%. Rezultati istraživanja pokazuju iste tri županije koje imaju najveći postotak i poznavanja pojma Mobilne poslovne inteligencije i korištenja iste.

3.1. Usporedba rezultata istraživanja korištenja poslovne inteligencije

Usporedivši rezultate istraživanja u Hrvatskoj i svijetu, vidljiva je sličnost u određenim pitanjima. Također, autorovo istraživanje je uspoređeno i sa istraživanjem poslovne inteligencije Bilandžić, Čulig, Lucić, Putar-Novoselec, Jakšić, 2011. godine.


Prema istraživanju poslovne inteligencije u hrvatskom gospodarstvu, Bilandžić, Čulig, Lucić, Putar-Novoselec, Jakšić, 2011. godine, tvrtke najviše prikupljaju podatke o gospodarskoj situaciji, konkurentskim strategijama i financijskim uvjetima, pravnoj regulaciji, potencijalnim potrošačima, potencijalnim poslovnim partnerima, potencijalnim poslovnim prilikama i mogućnostima, novim uslugama i proizvodima itd.



SLIKA 3. 27. Podaci koje prikupljaju tvrtke

Izvor: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=126155

U istraživanju koje je proveo autor, 2014. godine, najviše se prikupljaju sljedeći podaci: o kupcima, potencijalnim kupcima, dobavljačima, konkurentima, potencijalnim poslovnim prilikama i mogućnostima, novim proizvodima, uslugama i njihovim cijenama te o okruženju poslovanja tvrtke (pravna, gospodarska i politička situacija).



SLIKA 3. 28. Podaci koje tvrtke prikupljaju

Izvor: Izrada autora

Istraživanje provedeno 2005. godine od strane GIA (Global Intelligence Alliance), citirano prema Bilandžić, Čulig, Jakšić, Lucić, Novoselec (2011.), pokazalo je listu najpreferiranih pojmova kada je u pitanju prikupljanje, analiza i obrada podataka, koja se ne razlikuje mnogo od one dobivene istraživanjem autora. U svijetu su najpopularniji sljedeći pojmovi: istraživanje tržišta (market research) 30%, business intelligence 20%, competitive intelligence 16%, monitoring tržišta (market monitoring) 8%, competitor intelligence 5% i upravljanje znanjem (knowledge management) 3%.

Prema Bilandžić, 2008. U Hrvatskoj se business intelligence označava s nekoliko različitih pojmova kao što su: poslovno izvješništvo, poslovna inteligencija, poslovno-obavijesna aktivnost, gospodarsko obavješćavanje, poslovno-izvještajna aktivnost, poslovno istraživanje, upravljanje poslovnim informacijama, poslovno izvještavanje i ostalo.


TABLICA 3. 1. Usporedba pojmova za prikupljanje, analizu i obradu podataka

Najpreferiraniji pojmovi za prikupljanje, analizu i obradu podataka					
	Istraživanje tržišta	Business intelligence	Competitive intelligence	Monitoring tržišta	Upravljanje znanjem
Svijet 2005. godine	30%	20%	16%	8%	3%
Hrvatska 2014. godine	62,65%	37,35%	6,02%	19,28%	19,28%


Izvor: Izrada autora

Prema istraživanju Bilandžić, Čulig, Lucić, Putar-Novoselec i Jakšić, 2011. Primjena poslovne inteligencije u hrvatskim firmama je sljedeća: 57% tvrtki primjenjuje aktivnosti poslovne inteligencije, ali nemaju zaseban odjel, 19% tvrtki ima zaseban odjel poslovne inteligencije, dok 24% tvrtki ne primjenjuje aktivnosti poslovne inteligencije. Iz dobivenih rezultata je vidljivo da i dalje najveći broj tvrtki provodi aktivnosti poslovne inteligencije, ali nemaju zaseban odjel.

Istraživanjem je pokazano da vrlo mali broj malih i srednjih poduzeća u Hrvastkoj (1,2%) ima zaseban odjel poslovne inteligencije, što je razlika u odnosu na istraživanje provedeno 2011. godine u kojem 19% poduzeća imaju zaseban odjel, ali u navedenom istraživanju se radi o velikim poduzećima u Hrvatskoj.

**SLIKA 3. 29. Prikaz primjene business intelligence u hrvatskim tvrtkama**

Izvor: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=126155




SLIKA 3. 30. Primjena poslovne inteligencije u hrvatskim tvrtkama, 2014.godine

Izvor: Izrada autora

Rezultati dobiveni istraživanjem poslovne inteligencije 2014. godine od strane autora diplomskog rada, razlikuju se po tome što rezultati iz 2014. godine pokazuju veći postotak korištenja poslovne inteligencije u organizaciji – 72.29%, ali smanjenje korištenja poslovne inteligencije u zasebnom odjelu: 1.20%. Postotak o nekorisćenju poslovne inteligencije je gotovo identičan 2011. i 2014. godine: 2011.godine 24% tvrtki ne provodi aktivnosti poslovne inteligencije, a 2014. godine ih 25.3% ne provodi.

Rezultat istraživanja iz 2014. godine o korištenju poslovne inteligencije u malim i srednjim poduzećima u RH, ne razlikuje se mnogo od svjetske situacije te se može reći da Hrvatska ne zaostaje po tom pitanju za mnogim drugim državama.




SLIKA 3. 31. Primjena poslovne inteligencije u svjetskim tvrtkama, 2005.godine

Izvor: http://hrcak.srce.hr/index.php?show=clanak&id_clanak_jezik=126155

3.2. Usporedba istraživanja mobilne poslovne inteligencije u hrvatskoj i svijetu


Mobilna poslovna inteligencija se više koristi u svijetu, nego u Hrvatskoj. Prema istraživanju TDWI iz 2012. godine, više od 53% ispitanika je dalo odgovor da mobilnu poslovnu inteligenciju koristi manje od 10% zaposlenika unutar tvrtke, 16% je dalo odgovor da je koristi između 10 i 25% korisnika, a 9% između 26 i 50% (slika 3.32).



SLIKA 3. 32. Postotak korištenja MPI u svjetskim tvrtkama

Izvor: TDWI_BPReport_Q112_Mobile_Business_Intelligence_web.pdf

U Hrvatskoj je situacija sljedeća:



SLIKA 3. 33. Postotak korištenja MPI u hrvatskim tvrtkama

Izvor: izrada autora

U autorovom istraživanju ispitanicima je bilo postavljeno pitanje da li koriste mobilnu poslovnu inteligenciju u poduzeću, rezultat je da 61,45% ispitanika ne koristi, a 27,71% je koristi. Iako su pitanja postavljena različito u autorovom i svjetskom istraživanju, vidljivo je da više korisnika mobilne poslovne inteligencije postoji u svjetskim tvrtkama. 53% je onih koji su odgovorili da manje od 10% korisnika ipak koristi takve sustave, a zbrojimo li ostale korisnike mobilne poslovne inteligencije u svjetskim tvrtkama (od 10 do 100% korisnika), postotak korištenja je 34% što je ipak veći postotak nego u Hrvatskoj. TDWI u svom istraživanju navodi da svake godine prate trend rasta korisnika MPI u poduzećima.

U Hrvatskim tvrtkama MPI koriste: viši menadžeri (48,19%), IT stručnjaci ili programeri (27,71%), niži menadžment (18,07%), marketinški stručnjaci (18,07%), poslovni analitičari (10,84%) i ostali.

U svijetu su također viši menadžeri ti koji najviše koriste mobilnu poslovnu inteligenciju (29%), IT stručnjaci (23%), niži rukovoditelji i menadžeri (21%) te poslovni analitičari i analitičari podataka (17%).

Poredak prema postocima korištenja je gotovo jednak u Hrvatskoj i u svijetu. MPI najviše koriste menadžeri, jer im MPI inteligencija pomaže u donošenju poslovnih odluka, zatim IT stručnjaci koji najbolje razumiju problematiku takvih sustava ili sudjeluju u njihovoj implementaciji te marketinški stručnjaci i ostali analitičari koji analiziraju podatke.

Tablica 3. 2. Usporedba korištenja MPI prema grupama korisnika


Korisnici mobilne poslovne inteligencije u poduzeću				
	Viši menadžment	IT stručnjaci	Niži menadžment	Poslovni analitičari
Svijet 2012. god.	29%	23%	21%	17%
Hrvatska 2014. god.	48,19%	27,71%	18,07%	10,84%

Izvor: Izrada autora

Po pitanju toga na kojim se platformama/mobilnim uređajima koristi mobilna poslovna inteligencija, u svijetu je odgovor sljedeći: Apple iOS za iPad (67%), Apple iOS za iPhone (65%), Android sustav za pametne telefone (53%), RIM Blackberry za pametne telefone (53%), Android sustav za tablete (29%), Microsoft Windows sustav za pametne telefone (20%), RIM Blackberry za tablete (9%).

U Hrvatskoj je na prvom mjestu Android sustav za pametne telefone (51,81%), zatim Apple sustav za iPhone (43,37%), Apple operativni sustav za iPad (24,1%), Google Android za tablet (18,07%), Blackberry sustav za pametne telefone (9,64%) te Microsoft Windows Phone (6,02%).


Najpopularniji operativni sustavi i u Hrvatskoj i u svijetu su Apple operativni sustav za tablete i pametne telefone te Android sustavi za pametne telefone i tablete.



SLIKA 3. 34. Platforme za mobilnu poslovnu inteligenciju – svjetsko istraživanje

Izvor: TDWI_BPReport_Q112_Mobile_Business_Intelligence_web.pdf

Mobilne platforme/uređaji




SLIKA 3. 35. Platforme za mobilnu poslovnu inteligenciju – istraživanje u Hrvatskoj

Izvor: izrada autora

Aplikacije koje korisnici imaju implementirano na mobilnim uređajima ili ih planiraju implementirati su u autorovom istraživanju u Hrvatskoj: email (59,04%), sustav upozorenja (21,69%), proračunske tablice (18,07%), nadzorne ploče (16,87%), skladišta ili baze podataka (16,87%), poslovna inteligencija (15,66%) i ostalo.

U istraživanju TDWI, 2012. godine, 83% korisnika ima implementirano ili uskoro planira implementirati nadzorne ploče, zatim vizualizaciju podataka (69%), sustav upozorenja i aktivnosti (54%), napredna analitika i memorijska (*engl. in-memory*) poslovna inteligencija (32%), mobilna poslovna inteligencija integrirana s poslovnom inteligencijom na desktopu (29%), proračunske tablice (29%) i ostale.

Nadzorne ploče su najvažnija funkcionalnost poslovne i mobilne poslovne inteligencije, jer prikazuju izvještaje, upozorenja, analize i vizualizaciju podataka, a korisnici u svjetskim tvrtkama su prepoznali tu funkcionalnost i na prvom mjestu aplikacija u upotrebi su nadzorne ploče (*engl. dashboards*). U Hrvatskoj mali postotak korisnika ima implementirano nadzorne ploče, svega 16,87%, dok im je na prvom mjestu i dalje email (59,04%).



SLIKA 3. 36. Usporedba korištenja aplikacija u Hrvatskoj i svijetu

Izvor: Izrada autora


Po pitanju pristupa aplikacijama, u svijetu će korisnici najviše pristupati skladištima i bazama podataka (70%), izvješća (70%), proračunske tablice (44%), OLAP (43%) i ostale aplikacije kao što su: poslovna inteligencija u oblaku, ERP i CRM, dokumenti, obrasci itd.

U Hrvatskoj korisnici najviše pristupaju izvještajima (34,94%), zatim CRM (30,12%), skladišta ili baze podataka (28,92%), spremljeni podaci i analitika (25,30%), poslovna inteligencija u oblaku (18,07%) i ostale aplikacije kao što su: dokumenti i obrasci, vanjski podaci, OLAP, ERP itd.

Iz rezultata oba istraživanja, vidljivo je da i hrvatski i svjetski korisnici pristupaju istim aplikacijama, koje su različito poredane po važnosti.

U Hrvatskoj tvrtke kao dobavljače MPI najviše koriste: Oracle – 14,46% i SAP – 7,23%, dok su kao ostalo naveli vlastitu izradu rješenja poslovne inteligencije.

U svijetu, prema istraživanju Ventana research, najpoznatiji dobavljači su: Microstrategy 95,1%, IBM 93,5%, SAP 91,6% i ostale navedene na slici br.



SLIKA 3. 37. Najpoznatiji dobavljači MPI u svijetu

Izvor: <http://www.microstrategy.com/strategy/media/downloads/white-papers/ventana-research-mobile-bi-value-index-2014.pdf>

Prema istraživanju TDWI portala 2012. Godine uvođenjem mobilne poslovne inteligencije u tvrtke korisnici na svjetskoj razini očekuju: 53% korisnika će zahtijevati pristup skladištima podataka, 51% korisnika će zahtijevati veće funkcionalnosti samoposluživanja podacima, 49% korisnika će trebati edukaciju u vezi analitičkih alata i poslovne inteligencije, 46% će zahtijevati češće ažurirane podatke, 41% smatra da će biti potrebno nadograditi infrastrukturu u svrhu skalabilnosti i dostupnosti poslovne inteligencije. 26% smatra da će se povećati cloud korištenje cloud mobilne poslovne inteligencije, 12% ne zna odgovor.

U Hrvatskoj, prema istraživanju autora, situacija je sljedeća: 27,71 % će zahtijevati pristup skladištima podataka, 30,12% korisnika će zahtijevati veće samoposlužne funkcionalnosti, 34,94% korisnika će trebati edukaciju u vezi analitičkih alata i poslovne inteligencije, 34,94% će zahtijevati češće ažurirane podatke, 30,12% smatra da će biti potrebno nadograditi infrastrukturu u svrhu skalabilnosti i dostupnosti poslovne inteligencije, 24,10% smatra da će biti potrebno nadograditi infrastrukturu poslovne inteligencije za korištenje u oblaku i 16,87% je dalo odgovor da ne zna.

TABLICA 3. 3. Usporedba očekivanih promjena uvođenja MPI u Hrvatskoj i svijetu

Koje će se promjene dogoditi ako se sustav poslovne inteligencije proširi na korištenje na mobilnim uređajima						
	Više će korisnika zahtijevati pristup skladištima podataka	Korisnici će zahtijevati više samoposlužnih funkcionalnosti	Više će korisnika trebati edukaciju u vezi poslovne inteligencije i analitičkih alata	Mobilni korisnici će zahtijevati češće ažurirane podatke	Bit će potrebno nadograditi infrastrukturu za veću dostupnost podataka i skalabilnost	Bit će potrebno nadograditi infrastrukturu poslovne inteligencije za korištenje u oblaku
Svijet	53%	51%	49%	46%	41%	26%
Hrvatska	27,71%	30,12%	34,94%	34,94%	30,12%	24,10%

Izvor: Izrada autora

Iz dobivenih rezultata je vidljivo da korisnici u svijetu imaju veća očekivanja od uvođenja mobilne poslovne inteligencije nego korisnici u Hrvatskoj.


Jedan od razloga manjeg optimizma u vezi uvođenja mobilne poslovne inteligencije u Hrvatskoj u odnosu na svijet su: nedovoljan budžet 34,94%, nedovoljno znanje o mobilnim sustavima 24.10%, nepostojanje potrebe za mobilnom poslovnom inteligencijom u poduzeću

16,87% te strah od gubitka podataka 15,66%. Na svjetskoj razini korisnici vide mnoge prepreke, a to su: nemogućnost utvrđivanja povrata ulaganja 44%, nedostatak resursa, iskustva i edukacije 44%, pitanja sigurnosti podataka 41%, nedovoljan budžet 35%, poslovni slučaj nije dovoljno razrađen 33%, teža integracija s trenutnim alatima i aplikacijama 28%, nedovoljna podrška menadžera 22%, zabrinutost oko korisničkog usvajanja 19%, neadekvatno upravljanje podacima 17%, zabrinutost oko jednostavnosti upotrebe 16%, nezadovoljstvo sa softverskim opcijama MPI 12%, kvaliteta podataka nepovoljna za upotrebu 11%, nema prepreka 5%.

Korisnici vide veliki broj prepreka uvođenju mobilne poslovne inteligencije, a zajedničke prepreke na svjetskoj i Hrvatskoj razini su: nedovoljan budžet, strah od gubitka podataka te nedostatak resursa, edukacije i iskustva u vezi mobilnih sustava.

Hrvatskim tvrtkama je bitno da podaci budu pohranjeni na serveru (32,53%) te na serveru i na mobilnom uređaju (13,25%), dok je u svjetskim tvrtkama odgovor 50% podaci pohranjeni na uređaju, a 50% i na serveru i na uređaju.³

3 Prema istraživanju Mobile-BI-Market-Study-2012-Dresner-Advisory-Services.pdf



SLIKA 3. 38. Preferencije za pohranu podataka

Izvor: Izrada autora

4. ZAKLJUČAK

Kako bi tvrtke danas na tržištu ostvarivale konkurentsku prednost, nužno je prikupljanje, obrada i analiza podataka i to točna, brza i pravovremena. Aktivnost prikupljanja podataka te njihova analiza i pretvaranje u gotove poslovno-obavještajne analize ("znanje") radi pružanja potpore menadžmentu poslovnih subjekata s ciljem donošenja i realizacije što kvalitetnijih poslovnih odluka naziva se poslovna inteligencija.

Tvrtke koje posjeduju i koriste poslovnu inteligenciju bilježe rast prihoda i do 20% brže od svoje konkurencije (Luetić, 2008.)

U današnje vrijeme je najbitnija pravovremena informacija, a mobilna poslovna inteligencija to omogućuje. Mobilna poslovna inteligencija je primjena poslovne inteligencije na mobilnim uređajima. Mobilna poslovna inteligencija je logičan nastavak na sustav poslovne inteligencije i zahtjeve menadžera koji su povećali svoju pokretljivost i nisu vezani za radno mjesto te traže veću personalizaciju i intuitivnu vizualizaciju podataka.

Središnja hipoteza ovog rada je da u malim i srednjim poduzećima u Republici Hrvatskoj nije prepoznata važnost korištenja poslovne i mobilne poslovne inteligencije za donošenje poslovnih odluka, a slijedom toga ne postoje niti dobre strategije za upravljanje podacima koje podupiru poslovne ciljeve poduzeća. U istraživanju provedenom 2014. godine od strane autora diplomskog rada, vidljivo je da 72,29% poduzeća provodi aktivnosti poslovne inteligencije, dok samo 1,2% poduzeća ima zaseban odjel poslovne inteligencije. Može se zaključiti da je ipak više od polovice poduzeća iz istraživanja prepoznalo važnost poslovne inteligencije i iako nemaju zaseban odjel, prepoznale važnost njezina korištenja. Važnost korištenja sustava poslovne inteligencije u Hrvatskoj najviše su prepoznale tvrtke iz djelatnosti trgovine i informacijsko- komunikacijske djelatnosti.

Iz rezultata istraživanja 2011. godine (Bilandžić, Čulig, Lucić, Putar-Novoselec, Jakšić) i 2014. godine (od strane autora) vidljivo je da su i mala i srednja i velika poduzeća, prepoznala važnost korištenja poslovne inteligencije u svrhu donošenja poslovnih odluka, ali samo u velikim tvrtkama se formiraju zasebni odjeli za te aktivnosti.

Ukupno 89,15% tvrtki (istraživanje autora) je prepoznalo važnost korištenja sustava poslovne inteligencije te je ocjenjuju kao djelomično važnu i jako važnu.

Početna pretpostavka da tvrtke nisu prepoznale važnost korištenja poslovne inteligencije se ovim istraživanjem i radom pobija, jer većina tvrtki provodi aktivnosti poslovne inteligencije te smatra njezinu važnost korištenja djelomično i jako važnom.

Situacija glede mobilne poslovne inteligencije je znatno drugačija u odnosu na poslovnu inteligenciju. 56% tvrtki je upoznato s pojmom mobilne poslovne inteligencije, dok 37% nije niti upoznato s pojmom. Što se korištenja MPI tiče, samo 27,71% tvrtki je koristi. Početna hipoteza da važnost korištenja mobilne poslovne inteligencije nije prepoznata je potvrđena, jer je puno manji broj tvrtki koji je koriste u odnosu na one tvrtke, koje MPI koriste (27,71% koristi, dok 61,45% ne koristi). Iako tvrtke očekuju mnoge prednosti od uvođenja mobilne poslovne inteligencije, samo je 22% tvrtki spremno na njezinu implementaciju, a 14% smatra da će između 11 i 20% zaposlenika tvrtke prijeći na mobilnu poslovnu inteligenciju u narednih 12 mjeseci, što je vrlo mali i nimalo optimističan rezultat.

Kao najveće prepreke uvođenju mobilne poslovne inteligencije u poduzeće, tvrtke navode nedovoljan budžet te nedovoljno znanje o mobilnim sustavima.

Na svjetskoj razini je puno više tvrtki prepoznalo važnost korištenja poslovne i mobilne poslovne inteligencije te su takvi sustavi dio donošenja poslovnih odluka. Prema istraživanju Dresner-Advisory-Services iz 2012. godine, mobilnu poslovnu inteligenciju 34% organizacija smatra djelomično važnom, 43% jako važnom, a 18% neophodnom.

Pitanje koje se logički nameće je zbog čega postoji toliki manjak optimizma za korištenje sustava mobilne poslovne inteligencije. Korisnici kao najveću prepreku vide nedovoljan budžet, ali prednosti uvođenja sustava mobilne poslovne inteligencije su veći od troškova implementacije te kao prednosti, korisnici koji već koriste MPI navode: veću učinkovitost i koordinaciju poslovnih procesa, poboljšanu prodaju, usluge i podršku korisnicima te povećanu suradnju između zaposlenika što na kraju dovodi do poboljšanih financijskih rezultata poslovanja.

Sudeći po dobivenim rezultatima, vidljivo je da Hrvatska zaostaje iza svijeta u korištenju mobilne poslovne inteligencije. Kao aplikaciju je na mobilnim uređajima koristi 10,84% ispitanika, nasuprot 43% u svijetu.

Rezultati istraživanja pokazuju da su korisnici u Hrvatskoj manje optimistični glede uvođenja MPI u tvrtke, ali očekuju iste promjene kao i korisnici na svjetskoj razini.

Bitno je odrediti kojim podacima mogu pristupati određene grupe korisnika te onda i educirati korisnike za korištenje mobilne poslovne inteligencije kako bi takvi sustavi postali dostupni širem spektru korisnika, a ne samo menadžerima i IT stručnjacima.

Obzirom na sve veće zahtjeve tržišta i ne vezanost menadžera za jedno mjesto, mobilna poslovna inteligencija postat će nužna za donošenje poslovnih odluka, a tvrtke koje je uvedu prije ostalih, ostvarit će konkurentsku prednost na tržištu.

LITERATURA:

a) Internet linkovi:

1. <http://tdwi.org/portals/agile-bi.aspx> (14.3.2014.)
2. <http://www.sisense.com/what-is-in-memory-bi/> (14.3.2014.)
3. <http://www.gartner.com/it-glossary/self-service-business-intelligence> (23.4.2014.)
4. <http://searchbusinessanalytics.techtarget.com/definition/real-time-business-intelligence-BI> (23.4.2014.)
5. <http://www.ijikm.org/Volume2/IJIKMv2p135-148Olszak184.pdf> (22.4.2014.)
6. <http://www.skladistenje.com/skladno-skladistenje/> (22.4.2014.)
7. <http://www.information-management.com/specialreports/20020521/5211-1.html?zkPrintable=1&nopagination=1> (30.4.2014.)
8. <http://www.yellowfinbi.com/YFCommunityNews-Download-Dresner-s-2013-Wisdom-of-Crowds-Business-Intelligence-Market-Study-130791> (30.4.2014.)
9. <http://www.informationweek.com/big-data/big-data-analytics/gartner-bi-magic-quadrant-winners-and-losers/d/d-id/1114013> (30.4.2014.)
10. <http://tdwi.org/articles/2014/01/14/5-bi-trends-2014.aspx> (15.5.2014.)
11. <http://tdwi.org/Articles/2014/01/14/5-BI-Trends-2014.aspx?Page=3> (15.5.2014.)
12. <http://www.yellowfinbi.com/YFCommunityNews-Business-Intelligence-by-geography-Penetration-usage-trends-objectives-and-futur-143303> (16.5.2014.)
13. http://www.enterprisemanagement360.com/wp-content/files_mf/white_paper/sap-mobile_bi-v2.pdf (3.5.2014)
14. <http://www2.microstrategy.com/download/files/whitepapers/Mobile-BI-Insight-to-Action.pdf> (17.5.2014)
15. http://www.informationbuilders.com/sites/www.informationbuilders.com/files/pdf/about_us/whitepapers/wp_mobile_bi_101_wf2013.pdf (17.5.2014.)
16. <http://cumbersoness.com/sites/markfidelman/2012/05/02/the-latest-infographics-mobile-business-statistics-for-2012/> (17.5.2014.)
17. <http://venturebeat.com/2013/02/14/forresters-top-10-trends-for-mobile-in-2013/> (18.5.2014.)
18. http://www.informationbuilders.com/sites/www.informationbuilders.com/files/pdf/about_us/whitepapers/wp_mobile_bi_101_wf2013.pdf (18.5.2014.)

19. <http://searchbusinessanalytics.techtarget.com/essentialguide/Mobile-BI-tools-trends-and-best-practices-guide#guideCategory3> (18.5.2014.)
20. <http://searchbusinessanalytics.techtarget.com/feature/Growing-use-of-mobile-BI-apps-sparks-need-to-downsize-designs> (18.5.2014.)
21. <http://www2.microstrategy.com/download/files/whitepapers/Mobile-BI-Insight-to-Action.pdf> (19.5.2014.)
22. http://www.enterprisemanagement360.com/wp-content/files_mf/white_paper/sap-mobile_bi-v2.pdf (3.5.2014)
23. http://blogs.forrester.com/business_process/2009/11/not-all-mobile-bi-applications-are-created-equal.html (3.5.2014.)
24. <http://www.smartevision-online.com/NewWebsite/WhitePaper/Smart%20eVision%20White%20Paper%20-%20Mobile%20Technique%20and%20Features.pdf> (18.5.2014.)
25. <http://www.oracle.com/us/solutions/business-intelligence/oracle-mobile-bi-ebook-ds-501071.pdf> (18.5.2014.)
26. <http://v1.aberdeen.com/launch/report/perspective/8646-AI-mobile-applications-browser.asp?lan=US> (18.5.2014.)
27. https://bib.irb.hr/datoteka/583887.CASE-Mobilna_poslovna_inteligencija_i_racunarstvo_u_oblaku-ASTIPIC_TBRONZIN-1_3.pdf (6.5.2014.)
28. https://bib.irb.hr/datoteka/583887.CASE-Mobilna_poslovna_inteligencija_i_racunarstvo_u_oblaku-ASTIPIC_TBRONZIN-1_3.pdf, (7.5.2014.)
29. http://samples.sainsburysebooks.co.uk/9781743445105_sample_143914.pdf#page=7 (8.9.2014.)
30. TDWI_BPReport_Q112_Mobile_Business_Intelligence_web.pdf (23.4.2014.)
31. <http://ww2.ventanaresearch.com/rs/ventanaresearch/images/Ventana%20Research%20Value%20Index%202014%20Mobile%20Business%20Intelligence%20Executive%20Summary.pdf> (23.4.2014.)

b) Knjige:

1. Bilandžić, Mirko, (2008.), Poslovnoobavještajno djelovanje: business intelligence u praksi, Zagreb: AGM
2. Čerić, V. Varga, M. (2004). Informacijska tehnologija u poslovanju. Zagreb: Element
3. Mobile Business Intelligence: Intelligence at the Fingertips, School of Management Studies, University of Hyderabad, Hyderabad
4. Morgan Stanley (2009): The Mobile Internet Report
5. Moss, Atre: Business intelligence roadmap, 2008.
6. Panian, Klepac: Poslovna inteligencija, Masmedia, 2003
7. Sikavica, Novak (1999.), Poslovna organizacija, Zagreb: Informator

c) Članci

1. Ćurko (2001.): Skladište podataka – sustav za potporu odlučivanju, Hrčak, portal znanstvenih časopisa Republike Hrvatske
2. Stodder, Mobile Business Intelligence and analytics, TDWI, 2012.
3. Mobile Computing/Mobile Business Intelligence Market Study, Dresner Advisory Center, 2012
4. Bilandžić, Čulig, Lucić, Putar-Novoselec, Jakšić, Business Intelligence u Hrvatskom gospodarstvu, Hrčak, portal znanstvenih časopisa Republike Hrvatske, 2012.

POPIS SLIKA

Slika 1. 1. Infrastruktura sustava poslovne inteligencije.....	8
Slika 1. 2. Tehnička infrastruktura.....	12
Slika 1. 3. Dobavljači sustava poslovne inteligencije.....	18
Slika 2. 1. Infrastruktura MPI.....	31
Slika 2. 2. Nativna vs. Web bazirana rješenja	35
Slika 2. 3. Scenariji korištenja MPI u oblaku	38
Slika 3. 1. Postotak sudjelovanja u istraživanju po županijama.....	43
Slika 3. 2. Postotak sudionika prema poslovnim funkcijama.....	44
Slika 3. 3. Pojmovi za prikupljanje, analizu i obradu podataka	45
Slika 3. 4. Podaci koje tvrtke prikupljaju	46
Slika 3. 5. Primjena poslovne inteligencije u tvrtkama.....	47
Slika 3. 6. Važnost korištenja poslovne inteligencije za uspješnost poslovanja tvrtke	47
Slika 3. 7. Uspješnost upravljanja podacima u pogledu potpore poslovnim ciljevima poduzeća.....	48
Slika 3. 8. organizacijska strategija za upravljanje podacima	49
Slika 3. 9. Upoznatost s pojmom mobilne poslovne inteligencije.....	49
Slika 3. 10. Postotak korištenja mobilne poslovne inteligencije u malim i srednjim poduzećima u Hrvatskoj.....	50
Slika 3. 11. koje promjene korisnici očekuju uvođenjem sustava mobilne poslovne inteligencije	51
Slika 3. 12. Aplikacije kojima će korisnici najviše pristupiti uvođenjem MPI	52
Slika 3. 13. prednosti koje korisnici očekuju implementacijom sustava MPI.....	53
Slika 3. 14. Spremnost tvrtki na implementaciju MPI.....	54
Slika 3. 15. Spremnost tvrtki na implementaciju MPI.....	55
Slika 3. 16. Motivacija koja je prethodila uvođenju MPI u poduzeće	55

Slika 3. 17. Najčešće korištene aplikacije mobilne poslovne inteligencije.....	56
Slika 3. 18. Najčešće korišteni mobilni uređaji/platforme	57
Slika 3. 19. Najvažnije mogućnosti za korisnike MPI.....	58
Slika 3. 20. Korisnici MPI u poduzeću	59
Slika 3. 21. Postotak korisnika MPI u narednih 12 mjeseci.....	60
Slika 3. 22. Hoće li tradicionalni oblik PI biti zamijenjen mobilnom poslovnom inteligencijom unutar 24 mjeseca	61
Slika 3. 23. Pohranjivanje podataka MPI.....	61
Slika 3. 24. Dobavljači MPI u Hrvatskoj	62
Slika 3. 25. Prednosti koje poduzeću donosi korištenje MPI.....	63
Slika 3. 26. Koje aplikacije MPI tvrtke planiraju uvesti	64
Slika 3. 27. Podaci koje prikupljaju tvrtke	66
Slika 3. 28. Podaci koje tvrtke prikupljaju	67
Slika 3. 30. Prikaz primjene business intelligence u hrvatskim tvrtkama.....	68
Slika 3. 31. Primjena poslovne inteligencije u hrvatskim tvrtkama, 2014.godine	69
Slika 3. 32. Primjena poslovne inteligencije u svjetskim tvrtkama, 2005.godine	70
Slika 3. 33. Postotak korištenja MPI u svjetskim tvrtkama.....	70
Slika 3. 34. Postotak korištenja MPI u hrvatskim tvrtkama.....	71
Slika 3. 35. Platforme za mobilnu poslovnu inteligenciju – svjetsko istraživanje	72
Slika 3. 36. Platforme za mobilnu poslovnu inteligenciju – istraživanje u Hrvatskoj.....	73
Slika 3. 37. Usporedba korištenja aplikacija u Hrvatskoj i svijetu	74
Slika 3. 38. Najpoznatiji dobavljači MPI u svijetu	75
Slika 3. 39. Preferencije za pohranu podataka.....	78

POPIS TABLICA

Tablica 2. 1. Značajke MPI	22
Tablica 3. 1. Usporedba pojmova za prikupljanje, analizu i obradu podataka.....	68
Tablica 3. 2. Usporedba korištenja MPI prema grupama korisnika	72
Tablica 3. 3. Usporedba očekivanih promjena uvođenja MPI u Hrvatskoj i svijetu	76

SAŽETAK

Cilj ovog diplomskog rada je opisati sustave poslovne i mobilne poslovne inteligencije te istražiti njihovu primjenu u malim i srednjim poduzećima u Republici Hrvatskoj, a dobiveno istraživanje usporediti sa sličnim istraživanjima u svijetu.

Poslovna inteligencija je termin koji uključuje programe (aplikacije), infrastrukturu, alate i najbolje prakse koji omogućuju pristup i analizu podataka za poboljšanje i optimizaciju poslovnih odluka i performansi, a mobilna poslovna inteligencija se odnosi na primjenu poslovne inteligencije na mobilnim uređajima.

Provedeno je istraživanje na uzorku 83 poduzeća iz cijele Hrvatske o korištenju poslovne i mobilne poslovne inteligencije u malim i srednjim poduzećima.

Više od polovice poduzeća iz istraživanja je prepoznalo važnost poslovne inteligencije iako nemaju zaseban odjel poslovne inteligencije dok važnost korištenja mobilne poslovne inteligencije nije prepoznata u tolikoj mjeri. Više od polovice poduzeća ne koristi sustave mobilne poslovne inteligencije, a kao najveće prepreke uvođenju, tvrtke navode nedovoljan budžet te nedovoljno znanje o mobilnim sustavima. Korisnici koji već koriste MPI navode: veću učinkovitost i koordinaciju poslovnih procesa, poboljšanu prodaju, usluge i podršku korisnicima te povećanu suradnju između zaposlenika što na kraju dovodi do poboljšanih financijskih rezultata poslovanja.

KLJUČNE RIJEČI: poslovna inteligencija, mobilna poslovna inteligencija, istraživanje MPI, usporedba istraživanja

SUMMARY

The main aim of this thesis is to describe business and mobile business intelligence systems and explore their use in small and medium enterprises in Croatia. That research will be compared with similar researches in the world.

Business intelligence includes programs, applications, infrastructure and tools for gathering, storing, analyzing, and providing access to data to help users make better business decisions, and mobile business intelligence is application of business intelligence on mobile devices.

Within this thesis was made a research on the sample of 83 enterprises about using business and mobile business intelligence, in small and medium enterprises from Croatia. More than a half enterprises from the research recognized importance of using business intelligence despite that they don't have separate business intelligence department. Importance of using mobile business intelligence is not recognized and more than a half enterprises doesn't use it. The major obstacles for implementing mobile business intelligence systems are lack of knowledge for mobile systems and insufficient budget. Users who already have mobile business intelligence implemented see many advantages as: greater efficiency and business processes coordination, improved sales, service and customer support and increased cooperation between employees ultimately leading to improved financial results.

KEYWORDS: business intelligence, mobile business intelligence, mobile business intelligence research, research comparison